

UNIVERSIDAD AUTONOMA DE MADRID

ESCUELA POLITECNICA SUPERIOR



**Grado en Ingeniería de Tecnologías y Servicios de
Telecomunicación**

TRABAJO FIN DE GRADO

**MEJORA DE SISTEMAS DE AUTENTICACIÓN DE
PERSONAS BASADOS EN DINÁMICA DE RATÓN**

Belén Mérida Aguilera
Tutor: Aythami Morales Moreno
Ponente: Julián Fierrez Aguilar

Junio 2016

MEJORA DE SISTEMAS DE AUTENTICACIÓN DE PERSONAS BASADOS EN DINÁMICA DE RATÓN

AUTOR: Belén Mérida Aguilera
TUTOR: Aythami Morales Moreno

Biometric Recognition Group – ATVS
Dpto. de Tecnología Electrónica y de las Comunicaciones
Escuela Politécnica Superior
Universidad Autónoma de Madrid
Junio de 2016



Resumen

En este Trabajo Fin de Grado se estudia e implementa un sistema de autenticación de personas basado en dinámica de ratón. Los sistemas de autenticación de personas a partir de rasgos biométricos de comportamiento tienen cada vez mayor demanda. En este sentido, la dinámica de ratón se ha convertido en los últimos años en una interesante línea de investigación. Motivada por el impacto de la biometría web y de comportamiento, ésta biometría presenta gran potencial en multitud de escenarios dado su bajo coste y fácil implantación. Igual que la dinámica de tecleo, la dinámica de ratón se plantea como una alternativa a los sistemas tradicionales de autenticación y una garantía de la tan importante seguridad cibernética. Además, frente a otras tecnologías, permite llevar a cabo una monitorización continua de los usuarios, es decir, permite autenticación continua durante el uso de un servicio en contrapunto a la autenticación puntual única realizada al acceder al servicio. Todos estos factores han convertido a la dinámica de ratón en una herramienta muy atractiva para la industria digital.

Los trabajos realizados en este campo reseñan su utilidad y refuerzan su validez con sus resultados. Así, el objetivo del presente trabajo es evaluar el rendimiento de los sistemas planteados en la literatura y estudiar posibles mejoras de los mismos. Por tanto, el primer punto de este trabajo pasa por realizar una revisión del estado del arte. De todos los trabajos propuestos, se emplea un artículo de referencia. En éste se plantea una evaluación del rendimiento de diferentes implementaciones del problema. En base a ello, se diseña el sistema de mejor resultado y se analiza su rendimiento de acuerdo a las diferentes variables que componen el problema (usuarios, tareas, características). De forma paralela, se estudian nuevas aproximaciones del problema, ya empleadas en rasgos como la firma, basadas en modelos neuromotores asociados a la producción de las señales dinámicas involucradas en la dinámica de ratón. Tras el diseño de los diversos sistemas, se llevan a cabo una serie de experimentos a fin de efectuar diferentes evaluaciones. Finalmente, se presentan las conclusiones y se proponen futuras líneas de trabajo.

Palabras clave

Biometría, reconocimiento biométrico, reconocimiento de patrones, autenticación, dinámica de ratón, características, parametrización, base de datos, modelo Sigma-Lognormal.

Abstract

This Bachelor Thesis presents the study and implementation of an authentication system based on mouse dynamics. User authentication systems using behavioural biometrics are in increasing demand. In this regard, mouse dynamics has recently become an interesting research line. Driven by the impact of web and behavioural biometrics, mouse dynamics biometric shows great potential for many areas given its low cost and easy implementation. As with keystroke, mouse dynamics is proposed as an alternative to traditional authentication system and a guarantee of cybersecurity. In addition, compared to other technologies, it can be used in passive authentication, continuously validating user's identity while using a service in contrast to one-off authentication performed when accessing a service. All this factors have made mouse dynamics an attractive tool for the digital industry.

Previous research done in the area note its usefulness and reinforce its validity with their results. Thus, the aim of this study is to evaluate the performance of systems proposed in the literature and to study potential improvements. Therefore, the first block of this document is a review of the state of art. Of all research proposals, it is used one reference paper in particular. This paper presents a performance evaluation of different system implementations. On this basis, it is design the best system and its performance is analysed according to different parameters that define the problem (users, tasks, features). Alternatively, we study new approaches, already used in behavioural biometrics such as signature, based on neuromotor models associated to the production of dynamic signals involved in mouse activities. After the design stage, we conduct some experiments in order to perform different evaluations. Finally, we present the conclusions and, based on them, some future research lines.

Keywords

Biometrics, biometric recognition, pattern recognition, authentication, mouse dynamics, features, parameterization, database, Sigma-Lognormal model.

Agradecimientos

En primer lugar me gustaría dar las gracias a mi tutor, Aythami Morales, por brindarme la oportunidad de realizar este trabajo y guiarme siempre durante su desarrollo. Le agradezco, asimismo, el tiempo y esfuerzo invertidos. Agradecer a Moisés su colaboración al prestarnos sus conocimientos sobre el modelo neuromotor.

Este trabajo marca el fin de cuatro años muy especiales. Especiales por el apoyo de los que ya estaban, gracias chicas, y por personas nuevas que he podido conocer. Todo esto no hubiese sido ni parecido sin vosotros. Gracias Gonzalo por demostrarme que si se quiere, siempre se puede. Y gracias Jesús, demasiada paciencia has tenido.

Pero sobre todo quiero dar las gracias a mi familia. A mis padres, por su tesón y esfuerzo. Esto es sin duda fruto de vuestro trabajo. A mi hermana, por ser el mejor ejemplo a seguir.

Para ti, abuela, gracias.

Índice de contenidos

1	Introducción.....	1
1.1	Reconocimiento de patrones	1
1.2	Reconocimiento biométrico	2
1.2.1	Sistemas biométricos.....	4
1.2.2	Evaluación del rendimiento.....	5
1.3	Reconocimiento basado en dinámica de ratón	6
1.4	Modelo Sigma-Lognormal de la Teoría Cinemática	8
1.5	Motivación	10
1.6	Objetivos	10
1.7	Organización de la memoria	11
2	Metodología.....	13
2.1	Base de datos.....	13
2.1.1	Preprocesado de la base de datos	14
2.2	Extracción de características	15
2.2.1	Características de la literatura	16
2.2.1.1	Características holísticas	16
2.2.1.2	Características dinámicas	17
2.2.2	Características neuromotoras	20
2.2.2.1	Adaptación al modelo Sigma-Lognormal	20
2.2.2.2	Extracción de características neuromotoras	21
2.3	Método de comparación.....	23
2.4	Contribuciones del TFG.....	24
3	Experimentación.....	25
3.1	Protocolo de experimentación.....	25
3.1.1	Combinación de características	26
3.2	Pruebas y resultados.....	27
3.2.1	Pruebas sobre el detector basado en características de la literatura	27
3.2.2	Pruebas sobre el detector basado en características neuromotoras	31
3.2.3	Pruebas sobre el detector combinado	33
3.2.4	Pruebas sobre el modelado Sigma-Lognormal para detección de actividad humana.....	34

3.3 Contribuciones del TFG.....	36
4 Conclusiones y trabajo futuro	37
4.1 Conclusiones	37
4.2 Trabajo futuro	38
Referencias	39

Índice de figuras

FIGURA 1.1: DIAGRAMA DE BLOQUES DE UN SISTEMA BÁSICO DE RECONOCIMIENTO DE PATRONES.1	
FIGURA 1.2: SISTEMAS DE AUTENTICACIÓN. A LA IZQUIERDA, SISTEMAS DE AUTENTICACIÓN TRADICIONALES. A LA DERECHA, SISTEMAS DE AUTENTICACIÓN BIOMÉTRICOS.....	2
FIGURA 1.3: EJEMPLOS DE RASGOS BIOMÉTRICOS. A LA IZQUIERDA, RASGOS FISIOLÓGICOS. A LA DERECHA, RASGOS DE COMPORTAMIENTO.	3
FIGURA 1.4. DIAGRAMA DE BLOQUES DE UN SISTEMA BÁSICO DE RECONOCIMIENTO BIOMÉTRICO.	4
FIGURA 1.5. EJEMPLO DE CURVAS FAR Y FRR (IZQUIERDA) Y CURVA ROC (DERECHA).	5
FIGURA 1.6. EJEMPLO DE VARIABILIDAD INTRA-CLASE. SE MUESTRAN DOS REALIZACIONES (EN AZUL Y ROJO) DE UN MISMO EJERCICIO POR UN ÚNICO USUARIO.	6
FIGURA 1.7. PERFIL DE VELOCIDAD (SEÑAL NUMÉRICA) Y PATRÓN RECONSTRUIDO (SEÑAL ANALÍTICA) DE UNA TAREA BASADA EN DINÁMICA DE RATÓN.	9
FIGURA 2.1. EJERCICIO COMPLETO. LOS CÍRCULOS ROJOS REPRESENTAN LOS CLICS QUE DIVIDEN LA TAREA EN LOS 8 MOVIMIENTOS (EN TRAZO AZUL)	14
FIGURA 2.2. COMPARACIÓN DE MOVIMIENTOS TRAS FILTRADO.....	15
FIGURA 2.3. HISTOGRAMAS DE LA DISTANCIA DE MOVIMIENTO PARA TRES TRAMOS DEL EJERCICIO.	16
FIGURA 2.4. HISTOGRAMAS DEL OFFSET DE MOVIMIENTO PARA TRES TRAMOS DEL EJERCICIO.	17
FIGURA 2.5. HISTOGRAMAS DEL TIEMPO DE MOVIMIENTO PARA TRES TRAMOS DEL EJERCICIO.	17
FIGURA 2.6. ETAPAS DE EXTRACCIÓN DE CARACTERÍSTICAS DE LA LITERATURA.	18
FIGURA 2.7. HISTOGRAMAS DE LAS CARACTERÍSTICAS DINÁMICAS PARA TRES MOVIMIENTOS DEL EJERCICIO.....	19
FIGURA 2.8. INTERFAZ DE LA APLICACIÓN DE MODELADO NEUROMOTOR <i>SCRIPTSTUDIO</i>	20

FIGURA 2.9. ESQUEMA DE ADAPTACIÓN DE DATOS PARA EXTRACCIÓN DE CARACTERÍSTICAS NEUROMOTORAS.	21
FIGURA 2.10. EJEMPLO DE PARÁMETROS DE SALIDA DEL MODELO SIGMA-LOGNORMAL.....	21
FIGURA 2.11. HISTOGRAMAS DE LAS CARACTERÍSTICAS NEUROMOTORAS. SE REPRESENTA EL VALOR MEDIO POR USUARIO.	22
FIGURA 3.1. ESQUEMA DE DETECTOR CON COMBINACIÓN A NIVEL DE CARACTERÍSTICA.....	26
FIGURA 3.2. ESQUEMA DE DETECTOR CON COMBINACIÓN A NIVEL DE PUNTUACIÓN.	26
FIGURA 3.3. RESULTADOS DE EER POR USUARIO DEL CLASIFICADOR BASADO EN DISTANCIA MANHATTAN.	29
FIGURA 3.4. COMPARATIVA DE CURVAS ROC DEL USUARIO CON MEJOR Y PEOR RENDIMIENTO. ..	30
FIGURA 3.5. EJEMPLO DE TRES REALIZACIONES DE UN USUARIO QUE PRESENTA BAJA TASA DE ERROR.	31
FIGURA 3.6. EJEMPLO DE TRES REALIZACIONES DE UN USUARIO QUE PRESENTA ALTA TASA DE ERROR.	31
FIGURA 3.7. COMPARACIÓN DE CARACTERÍSTICAS NEUROMOTORAS PROMEDIADAS DE LOS USUARIOS CON PEOR (EN ROJO) Y MEJOR RENDIMIENTO (EN VERDE) SOBRE LOS HISTOGRAMAS DEL CONJUNTO COMPLETO DE USUARIOS.	33
FIGURA 3.8. REALIZACIÓN SIMULADA.	34
FIGURA 3.9. PARAMETRIZACIÓN DEL MODELO SIGMA-LOGNORMAL DE LA REALIZACIÓN DE LA FIGURA 3.8.	35
FIGURA 3.10. COMPARACIÓN DE UN PERFIL DE VELOCIDAD DE UN USUARIO (ARRIBA) Y DE UNA MÁQUINA (ABAJO).	36

Índice de tablas

TABLA 2.1. LISTADO DE MOVIMIENTOS QUE COMPONEN EL EJERCICIO. DATOS OBTENIDOS DE [5].13	
TABLA 2.2. PARÁMETROS DEL MODELO SIGMA-LOGNORMAL Y CARACTERÍSTICAS NEUROMOTORAS.	23
TABLA 3.1. TABLA RESUMEN DEL MARCO EXPERIMENTAL.	25
TABLA 3.2. RESULTADOS DE EER Y DESVIACIÓN ESTÁNDAR SEGÚN MOVIMIENTO INCLUIDO.	27

TABLA 3.3. RESULTADOS DE EER PROMEDIO Y DESVIACIÓN ESTÁNDAR SEGÚN CARACTERÍSTICAS INCLUIDAS EN EL DETECTOR.....	28
TABLA 3.4. RESULTADOS DE EER PROMEDIO Y DESVIACIÓN ESTÁNDAR SEGÚN CARACTERÍSTICAS ELIMINADAS DEL DETECTOR.....	29
TABLA 3.5. RESULTADOS DE EER PROMEDIO Y DESVIACIÓN ESTÁNDAR SEGÚN CARACTERÍSTICAS NEUROMOTORAS INCLUIDAS.	32
TABLA 3.6. CARACTERÍSTICAS NEUROMOTORAS PROMEDIADAS DE LOS USUARIOS CON PEOR Y MEJOR RENDIMIENTO.....	32
TABLA 3.7. RESULTADOS DE EER PROMEDIO Y DESVIACIÓN ESTÁNDAR DEL DETECTOR COMBINADO.	34
TABLA 3.8. COMPARACIÓN DE PARÁMETROS LOGNORMAL ENTRE USUARIOS REALES Y UNA REALIZACIÓN SIMULADA POR LA MÁQUINA.	35

1 Introducción

Este capítulo resumirá los aspectos generales de la biometría y el reconocimiento de patrones, con especial profundidad en el campo en el que se ha desarrollado este trabajo, la dinámica de ratón. Se presentarán también la organización de la memoria y la motivación y objetivos que han guiado este Trabajo Fin de Grado.

1.1 Reconocimiento de patrones

En el contexto de este trabajo, el reconocimiento de patrones es la ciencia encargada de la descripción y clasificación de objetos mediante la extracción automática y análisis de información. Estos objetos varían según la aproximación y el campo de aplicación, pudiendo tratarse de locuciones, imágenes, firmas, etc. El término *patrones* hace referencia al resultado de la adquisición de estos objetos. Mediante el análisis de los mismos, se persigue hacer una agrupación en clases definidas por ciertas propiedades comunes. El objetivo del reconocimiento de patrones es que esta asociación, realizada en base a la similitud entre patrones, se realice de forma automática. Para permitir esta automaticidad, el sistema desarrollará un proceso de aprendizaje a partir de la construcción de modelos de cada clase según un conjunto de características.

El esquema de un sistema de reconocimiento de patrones incluye, de forma genérica, tres etapas: adquisición de datos, extracción de características y clasificación. En cada etapa se adaptarán los datos a la siguiente fase a fin de obtener resultados sobre los que extraer una decisión. La figura 1.1 esquematiza los componentes básicos de un sistema biométrico.



Figura 1.1: Diagrama de bloques de un sistema básico de reconocimiento de patrones.

La adquisición de datos es llevada a cabo mediante un sensor o transductor que digitaliza el rasgo capturado. La importancia de este dispositivo reside en la calidad con la que los datos sean recogidos. Este aspecto repercute en todas las etapas sucesivas y, por tanto, en el rendimiento del sistema. Por ello, es común que el extractor sea precedido por una etapa de preprocesamiento de los datos adquiridos, por ejemplo, filtrado de ruido, normalización, eliminación de muestras repetidas, etc.

Una vez acondicionados los datos, se realiza la extracción de características, es decir, el cálculo de parámetros, sobre la señal, considerados discriminantes para la tarea de clasificación. La parametrización es una de las etapas más importantes de un reconocedor porque reduce los datos a procesar, trasladándolos a un nuevo espacio de características donde la tarea de clasificación es más sencilla. El objetivo es que el conjunto de características seleccionadas determinen un modelo o clase. Así, el clasificador genera una puntuación o *score* a partir de la comparación entre modelos. De esta puntuación y, junto a un umbral, se lleva a cabo la decisión entre clases.

El margen de aplicaciones de los sistemas de reconocimiento de patrones es muy amplio. Algunos ejemplos de aplicación son el reconocimiento de caracteres, la cartografía, el reconocimiento automático del habla, el guiado de vehículos y el reconocimiento biométrico de personas [1]. El último campo mencionado, reconocimiento biométrico de personas, es el que conforma este Trabajo Fin de Grado.

1.2 Reconocimiento biométrico

El término *reconocimiento biométrico* se atribuye a la disciplina científica dedicada al reconocimiento de personas en base a sus atributos físicos o de comportamiento. De acuerdo a esto, se entiende que el reconocimiento biométrico encuentre en el reconocimiento de patrones su fundamento de cálculo.

Los humanos, desde sus orígenes, han empleado rasgos como la voz o el rostro para identificarse mutuamente. A mediados del siglo XIX, el jefe de la división de identificación criminal del Departamento de Policía de París, Alphonse Bertillon, ideó y puso en práctica el uso de rasgos fisiológicos para la identificación criminal. Décadas después, y pese a su incremento en popularidad, esta idea fue eclipsada por el descubrimiento de la eficiencia de las huellas dactilares. Así, comenzaron a desarrollarse las primeras bases de datos de huellas dactilares [2]. Hoy en día, los objetivos que persigue la aplicación del reconocimiento biométrico van mucho más allá de la identificación criminal.

En las últimas décadas, la necesidad de sistemas precisos de autenticación de personas se ha visto incrementada, y de ahí que el reconocimiento biométrico tenga, hoy, amplia relevancia. Habitualmente, el objetivo general es tratar de evitar el acceso de impostores a un determinado recurso protegido. Sin embargo, las posibilidades de esta disciplina son potencialmente superiores. Servicios de banca online, reconocimiento forense o seguridad informática son solo algunos campos en los que la biometría configura el papel principal.

La ventaja de los sistemas biométricos reside en que la identidad no está basada en contraseñas o tarjetas (algo que sabemos o tenemos), sino en el individuo en sí. Esto es, el sujeto fundamental del reconocimiento biométrico es el propio cuerpo humano y sus características físicas y conductuales [1]. No importa lo que el individuo *posea* o *sepa*, sino que la identificación se realiza en base a lo que *es* [2]. La figura 1.2 expone algunos ejemplos de sistemas de autenticación tradicionales frente a sus sustitutos, biométricos.



Figura 1.2: Sistemas de autenticación. A la izquierda, sistemas de autenticación tradicionales. A la derecha, sistemas de autenticación biométricos.

El reconocimiento biométrico de personas pretende asignar o verificar la identidad de los usuarios a partir de la medida de algunas características propias de la persona, como las ejemplificadas en la figura anterior. Según las características o rasgos empleados en la tarea de identificación se diferencian dos grandes grupos [1]:

- **Biometría fisiológica:** referida al conjunto de rasgos estrictamente físicos como son la huella dactilar y palmar, la retina e iris o la geometría de la cara y mano. Estos rasgos exigen una etapa de adquisición más costosa e invasiva. Sin embargo, presentan menor variabilidad con el paso del tiempo.
- **Biometría conductual:** referida al conjunto de rasgos de comportamiento o conductuales. La voz, el tecleo, la firma y la forma de andar son algunos ejemplos de este tipo de rasgos. Presentan mayor variabilidad en relación, por ejemplo, al paso del tiempo o al contexto emocional. La dinámica de ratón, rasgo en el que se basa este TFG, se encuentra en este grupo.

La figura 1.3 resume la clasificación de los rasgos biométricos con algunos ejemplos.

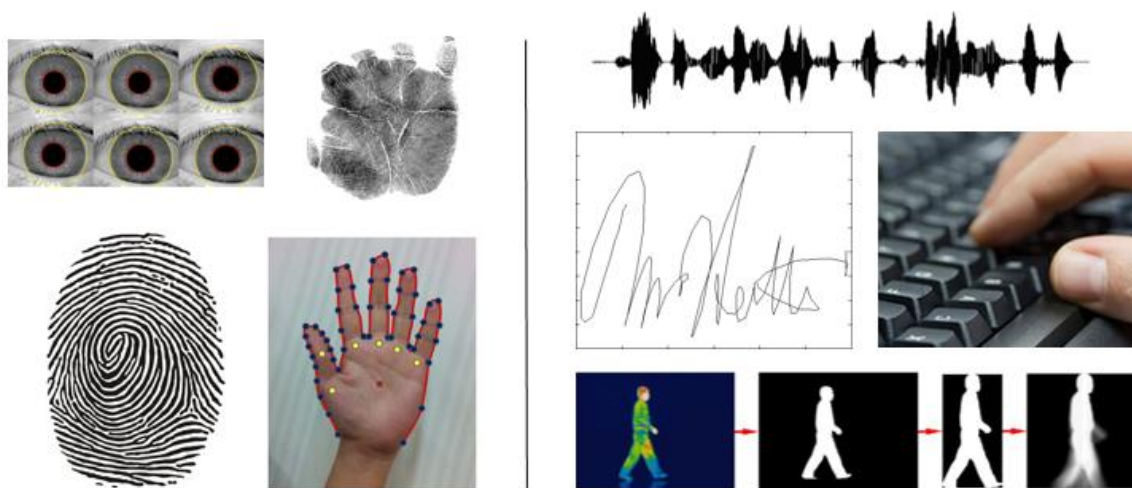


Figura 1.3: Ejemplos de rasgos biométricos. A la izquierda, rasgos fisiológicos. A la derecha, rasgos de comportamiento.

Cada uno de estos rasgos biométricos, y cualquier otra característica humana, puede aplicarse a sistemas de reconocimiento. Sin embargo, no todos ellos resultan igual de discriminantes y efectivos. Su idoneidad dependerá de la aplicación a la que se destine. Para determinar su validez se definieron los siguientes requisitos [3]:

- **Universalidad:** todo individuo debe poseer el rasgo empleado en la aplicación.
- **Unicidad:** el rasgo debe ser suficientemente diferente, o discriminante, entre los individuos que comprenden la población a identificar.
- **Estabilidad:** el rasgo biométrico debe ser invariante a lo largo del tiempo.
- **Mensurabilidad:** ha de ser posible adquirir y digitalizar el rasgo biométrico mediante dispositivos que no ocasionen molestias a los usuarios.
- **Rendimiento:** la precisión y los recursos del sistema deben cumplir los requerimientos impuestos por la aplicación.
- **Aceptabilidad:** se debe contar con la conformidad de los usuarios para proporcionar su rasgo biométrico al sistema.

- **Usurpación:** el sistema debe ser robusto a imitaciones desarrolladas con procedimientos fraudulentos.

Estos requerimientos persiguen establecer un conjunto de herramientas que den lugar a un sistema de reconocimiento biométrico robusto y eficiente. No obstante, no existen rasgos ideales que cumplan por completo estos requerimientos. La elección de uno u otro en la conformación del sistema dependerá de las características propias de la aplicación final.

1.2.1 Sistemas biométricos

Un sistema biométrico no es más que un sistema de reconocimiento de patrones cuyos datos de entrada son rasgos biométricos. Además, cuenta con una primera etapa de **registro** de usuarios, a fin de conformar la base de datos con la que posteriormente comparar. En definitiva, la base de datos almacena los modelos de usuarios empleados por el clasificador, véase la figura 1.4.

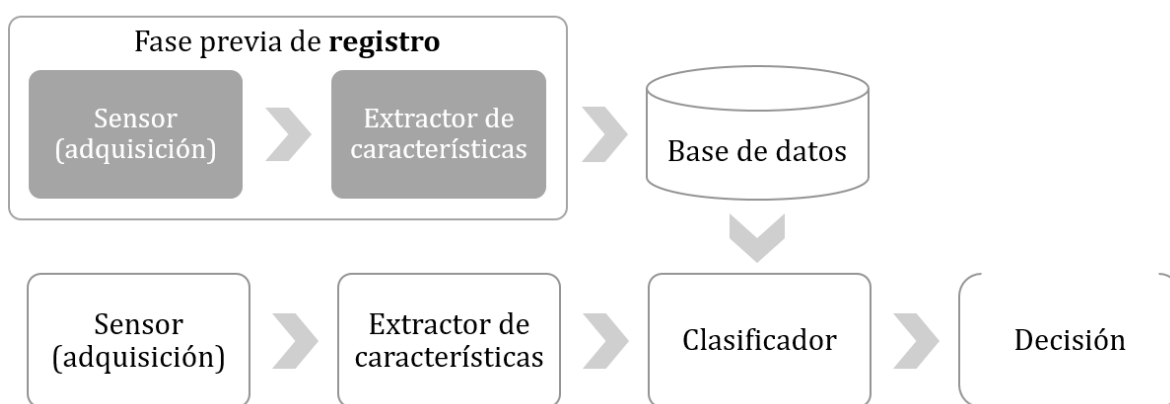


Figura 1.4. Diagrama de bloques de un sistema básico de reconocimiento biométrico.

En función de la aplicación, un sistema biométrico operará en uno de los siguientes modos:

- **Verificación o autenticación:** En una tarea de autenticación se realiza una comparación uno-a-uno entre el modelo de usuario y la nueva realización. El usuario se identifica al sistema y se extrae su modelo de la base de datos. La puntuación derivada de la comparación, junto a un umbral, permite al sistema tomar una decisión; es decir, clasificar al usuario como genuino, si es quien dice ser, o como impostor. El objetivo es, por tanto, validar la identidad proporcionada por un usuario.
- **Identificación:** En una tarea de identificación se realiza una comparación uno-a-muchos entre los modelos de múltiples usuarios y la nueva realización de un único usuario. Se extrae una puntuación por cada comparación y se elabora un listado de candidatos con las de mayor valor. Si ninguna de las puntuaciones del listado supera un cierto umbral, a modo de verificación, se considera que el usuario no se encuentra en la base de datos. A diferencia de la autenticación, en este modo, el usuario no proporciona su identidad, sino que se obtiene a la salida del comparador, en caso de encontrarse en la base de datos. El objetivo es, por tanto, encontrar la identidad de un usuario.

1.2.2 Evaluación del rendimiento

La implementación de un sistema de reconocimiento biométrico requiere mecanismos que evalúen su capacidad. Una medida de su bondad y rendimiento permitirá mejorarlo y compararlo con otros sistemas existentes. El análisis y tratamiento de errores en verificación parte de la puntuación o *score* extraído por el clasificador y la decisión final del sistema, sección 1.1. En este punto se pueden cometer dos tipos de errores:

- Un usuario impostor es etiquetado erróneamente por el sistema como usuario genuino. Esto recibe el nombre de **falsa aceptación**, FA, y se produce cuando la puntuación generada por modelos pertenecientes a diferentes usuarios supera el umbral de decisión fijado. Denominaremos FAR, por sus siglas en inglés, a la tasa de falsa aceptación del sistema.
- Un usuario genuino es etiquetado erróneamente por el sistema como usuario impostor. Esto recibe el nombre de **falso rechazo**, FR, y se produce cuando la puntuación generada por modelos pertenecientes a un mismo usuario no supera el umbral de decisión fijado. Denominaremos FRR, por sus siglas en inglés, a la tasa de falso rechazo del conjunto.

Ambos errores se miden para valores concretos de umbrales de decisión. La relación entre proporción de puntuaciones cometiendo errores de FA y FR es inversa. La tasa de falsa aceptación siempre decrece a medida que disminuye el umbral puesto que aumenta la probabilidad de aceptar a un usuario impostor. Por el contrario, la tasa de falso rechazo crece según lo hace el umbral pues aumenta la probabilidad de rechazar a un usuario genuino.

En un sistema ideal, las curvas FAR y FRR quedarían separadas por el umbral de decisión sin zona de solapamiento alguna. La realidad es que ambas se superponen. El punto en el que coinciden se denomina **EER** (Equal Error Rate) y se emplea como valor de referencia para medir la bondad de un sistema. La representación de FAR frente a FRR para un rango de umbrales de decisión de análisis se conoce como **curva ROC**, véase la figura 1.5. Esta curva permite comparar de forma gráfica distintos tipos de sistemas.




Figura 1.5. Ejemplo de curvas FAR y FRR (izquierda) y curva ROC (derecha).

1.3 Reconocimiento basado en dinámica de ratón

El reconocimiento basado en dinámica de ratón analiza los patrones de uso del ratón para la clasificación, verificación y/o identificación de usuarios. Similar a la dinámica de tecleo, la dinámica de ratón es un rasgo biométrico conductual que presenta una elevada **variabilidad intra-usuario**. Esto es, mismas realizaciones de un único individuo pueden resultar muy diferentes. La figura 1.6 ejemplifica este factor representando dos realizaciones, en azul y rojo, de un mismo usuario. Factores como la posición del usuario frente al ratón, el tipo de ratón o el tipo de superficie sobre la que se emplee conllevan versiones genuinas muy dispares de un mismo usuario.

Dicha variabilidad lleva a pensar que la dinámica de ratón no sea un rasgo suficientemente discriminante para tareas de identificación. Sin embargo, por ser un rasgo de comportamiento básico y de fácil adquisición, sí resulta útil para tareas de autenticación y detección de anomalías.

La dinámica de ratón permite llevar a cabo tanto autenticación activa como pasiva. En **autenticación activa**, el usuario provee su rasgo biométrico a fin de acceder a un determinado servicio o información. Por otro lado, en **autenticación pasiva**, se válida continuamente la identidad del usuario adquiriendo sus datos sin que éste sea consciente [4]. Así, este rasgo biométrico tiene la ventaja de ser no intrusivo, no requerir hardware específico para su adquisición y permitir la verificación continua o monitorización del comportamiento durante una sesión. En un ejemplo práctico, un usuario tratando de iniciar sesión proveería su nombre de usuario y una serie de movimientos de ratón específicos. El usuario sería autenticado y aceptado si sus movimientos se ajustan a su modelo; en caso contrario, sería rechazado. Además, en modo pasivo, sus movimientos de ratón podrían ser analizados durante la sesión, pudiendo detectar posibles sustituciones de usuario tras la verificación inicial. Este modo, por tanto, permite contemplar la dinámica de ratón como una opción apropiada para sistemas de detección de intrusos.




Figura 1.6. Ejemplo de variabilidad intra-clase. Se muestran dos realizaciones (en azul y rojo) de un mismo ejercicio por un único usuario.

La dinámica de ratón se ha convertido en un campo de investigación muy activo en las últimas décadas [5]. Desde que, en 1998, Syukri *et al.* [7] investigasen si firmas escritas con un ratón resultaban discriminantes para identificar usuarios, se han propuesto múltiples técnicas y usos de la dinámica de ratón. Hay dos usos de interés principales: el análisis estático o activo y el análisis continuo o pasivo [5], anteriormente mencionados. A su vez, existen diferentes enfoques dentro de cada tipo de análisis. Uno de ellos es la detección de anomalías de una única clase. Las muestras recogidas de un usuario genuino conforman un modelo de comportamiento por individuo que es utilizado para detectar impostores. Por el contrario, en un modelo multi-clase, las muestras de múltiples usuarios se emplean para entrenar el clasificador de forma que sea capaz de discriminar entre diferentes clases. Por su relevancia en este TFG, nos centramos en el análisis estático de la dinámica de ratón para la detección de anomalías de una única clase (usuario genuino).

El primer detector desarrollado por Syukri *et al.* [7], que empleaba la distancia Euclídea sobre un conjunto de datos de usuarios legítimos recogidos en un entorno controlado, conseguía unos resultados FAR de 8% y FRR de 9%. Tras esta primera aproximación, se implementaron diversos clasificadores empleando algoritmos basados en redes neuronales [8], [14], detección de outliers [4], [9], [10], distribución de Weibull [11], distancia de Levenshtein [12] y distancia Mahalanobis [13]. La particularidad de todos estos trabajos es que emplean especificidades diferentes en cuanto número de usuarios, conjunto de características, datos de entrenamiento, hardware empleado en la adquisición, escenario de ejercicios de dinámica de ratón, etc. Esta falta de control impide evaluar el rendimiento y extraer conclusiones objetivas de la comparación entre ellos [5].

En 2014, Chao *et al.* [5] presentaron una evaluación del rendimiento de un conjunto de algoritmos de detección. Para ello, crearon una base de datos pública que permitiera la comparación bajo las mismas condiciones experimentales. El conjunto de datos contiene muestras de 58 sujetos recogidas en un escenario completamente controlado. La evaluación de cada detector se realizó bajo las mismas condiciones empleando los mismos procedimientos de análisis.

A continuación se resumen las etapas seguidas por Chao *et al.* [5] para la evaluación e implementación de los clasificadores mencionados.

- **Colección de datos.** Se diseñó un ejercicio compuesto por 8 movimientos consecutivos separados por clics. La tarea recoge tres propiedades básicas de la dinámica de ratón: dirección de movimiento, distancia y clic. Cada usuario, del total de 58, debía completar dos repeticiones del ejercicio al día, hasta obtener un total de 300 repeticiones sin errores. Para la adquisición de estos datos se empleó el mismo hardware con una frecuencia de muestreo de 15.625ms. Todos los usuarios eran diestros y contaban con una experiencia de al menos dos años en el manejo del ratón.
- **Extracción de características.** Las características extraídas se dividen en dos grupos: características holísticas y características dinámicas o de procedimiento. Las características holísticas describen propiedades globales de la dinámica de ratón, como la distancia, duración y offset del movimiento. Por otro lado, las características que describen la dinámica de cada movimiento son las relativas a velocidad y aceleración. En total, extrajeron 13 características para cada uno de los 8 movimientos que conforman el ejercicio. De esta forma, cada muestra es caracterizada por un vector de dimensión igual a $13 \times 8 = 104$ características.
- **Implementación de detectores.** Se desarrollaron 17 detectores de anomalías de una única clase. Típicamente, una tarea de autenticación es un problema de dos clases, usuarios genuinos vs. impostores. Sin embargo, la implementación de un detector

suele contar únicamente con la información genuina, tornándose un problema de una clase. Cada detector tiene dos estados: entrenamiento y test. En el entrenamiento, un conjunto de características pertenecientes a un usuario genuino se emplean para generar el modelo o perfil de usuario. En el test, el detector compara un nuevo vector con el modelo y calcula la puntuación como medida de similitud entre ambas. El proceso de cálculo del score es lo que varía en cada uno de los 17 detectores desarrollados.

- **Metodología de evaluación.** Cada detector se entrenó con las 100 primeras muestras, del total de 300, para generar el modelo de usuario. El conjunto de muestras restantes se emplearon en el test para calcular la puntuación o score. Se evaluó la capacidad del detector para reconocer impostores calculando la puntuación de todas las muestras pertenecientes a impostores. A partir de éstas se calculan las curvas FAR y FRR y el EER. El umbral de decisión se ajustó al EER.
- **Experimentos.** Para obtener un análisis objetivo del rendimiento, Chao *et al.* [5] evaluaron la sensibilidad al tamaño de muestras de entrenamiento, la usabilidad respecto a la longitud de muestras y la escalabilidad según el número de usuarios. A medida que aumenta el tamaño de muestras de entrenamiento y la longitud, mejoran los resultados de error. Los rendimientos obtenidos (EER) varían entre un 8.81% y 69.46%, con resultados prometedores incluso con los clasificadores más sencillos.

El proyecto expuesto [5] ha sido el primero en establecer una plataforma de datos pública sobre la que implementar diferentes sistemas de cara a impulsar la investigación y clarificar el estado actual del campo del reconocimiento basado en dinámica de ratón.

El presente trabajo, haciendo uso de la base de datos publicada, tratará de corroborar sus resultados y extraer conclusiones sobre el reconocimiento basado en dinámica de ratón. Se ha de tener en cuenta que, a diferencia del reconocimiento facial o de huella dactilar, la dinámica de ratón es un rasgo biométrico de comportamiento. En este sentido, la variabilidad presentada es más que elevada. Por ello, los esfuerzos deben centrarse en desarrollar técnicas eficientes que mitiguen dicha inestabilidad y encontrar características que representen la información discriminante del conjunto de datos. En esta línea, se propone explorar nuevas técnicas basadas en la Teoría Cinemática de los movimientos humanos rápidos, véase la sección contigua.

1.4 Modelo Sigma-Lognormal de la Teoría Cinemática

El modelo Sigma-Lognormal es una representación basada en la Teoría Cinemática que descompone modelos complejos de señal en una combinación de trazos primitivos. Cada trazo tiene un perfil de velocidad lognormal y sumando varios se conforma un patrón complejo, según:

$$v(t) = \sum_{i=1}^N v_i(t)$$

donde $v_i(t)$ es el perfil de velocidad del i -ésimo primitivo y N el número de trazos que componen el patrón [15][16]. Se emplea una Sigma-Lognormal para modelar cada uno de los trazos, resultando una parametrización con un vector de seis características:

$$P_i = (t_{0i}, D_i, \theta_{di}, \theta_{fi}, \mu_i, \sigma_i)$$

donde t_{0_i} representa el tiempo de inicio de ejecución del trazo, D_i su longitud, θ_{d_i} y θ_{f_i} los ángulos direccionales de inicio y fin, μ_i el retraso logtemporal y σ_i el tiempo de respuesta al impulso del sistema neuromuscular. Estos parámetros caracterizan el proceso de control motor y la respuesta neuromuscular de un movimiento [16].

Este modelo contempla las características físicas y cognitivas del humano relativas al sistema neuromuscular. Cabe pensar que el hecho de modelar el movimiento según esta técnica puede tener sentido para la dinámica de ratón, por ser un ejercicio muscular dirigido por el sistema cognitivo. En este contexto, cada tarea completa quedaría definida por una suma vectorial de perfiles de velocidad lognormal. La figura 1.7 recoge la reconstrucción de un ejercicio de ratón y su perfil de velocidad asociado. En la parte de arriba de la figura 1.7 se puede apreciar cómo la tarea está compuesta por una combinación de funciones sigma-lognormal que representan las velocidades de activación muscular (velocidad creciente) y desactivación muscular (velocidad decreciente) en las tareas de neuromotoras.




Figura 1.7. Perfil de velocidad (señal numérica) y patrón reconstruido (señal analítica) de una tarea basada en dinámica de ratón.

Hasta la fecha, su aplicación en el campo del reconocimiento basado en dinámica de ratón cuenta con escasas referencias. Sin embargo, la Teoría Cinemática sí se ha usado ya en el análisis de diversas tareas manuscritas, como la firma [15][16].

1.5 Motivación

El reconocimiento biométrico se ha establecido como una herramienta básica para multitud de escenarios: control de acceso a zonas restringidas, autenticación de documentos, gestión de identidades a gran escala, servicios bancarios, seguridad, etc. En este sentido, y particularmente en los últimos años, la proliferación de los servicios web ha traído consigo nuevos requerimientos en los sistemas de autenticación. La seguridad cibernética ha planteado serios problemas desde sus inicios. Servicios de banca online o plataformas de almacenamiento de información en el espacio virtual demandan formas sencillas y seguras de identificación de personas, capaces de sustituir sistemas tradicionales (basados en contraseñas o tarjetas de identificación). Por estas razones, el reconocimiento biométrico aplicado a la web se ha convertido en un área de investigación muy activo.

La dinámica de ratón es la incursión más reciente dentro de la biometría web. Igual que la dinámica de tecleo, la dinámica de ratón se plantea como una alternativa a los sistemas tradicionales de autenticación y una garantía de la tan importante seguridad cibernética. Frente a otras tecnologías, la dinámica de ratón permite llevar a cabo una monitorización continua de los usuarios. En una situación real, un usuario podría acceder a un servicio mediante la ejecución de ciertos movimientos de ratón y, una vez aceptado, en caso de ser sustituido por un impostor durante la sesión, sería rechazado gracias a la monitorización. Esta idea permitiría prescindir del uso de contraseñas, vulnerables a robos y frecuentemente olvidadas.

Los trabajos realizados en el campo de la dinámica de ratón, expuestos en la sección 1.3, reseñan el potencial de esta tecnología. Sin embargo, los rendimientos aún distan de ser los deseables [5] y se ha profundizado poco en los modelos de producción neuromotores asociados a las tareas con ratón.

A fin de avanzar en este ámbito, además de las técnicas de la literatura, entra en papel la Teoría Cinemática, la cual ha sido aplicada con éxito en el ámbito de la escritura manuscrita. Como se ha mencionado en la sección 1.4, la aplicación del modelo Sigma-Lognormal en la dinámica de ratón cuenta con escasas referencias. No obstante, en otros campos del reconocimiento biométrico, como la firma, el modelo ha resultado una muy buena herramienta [15][16].

1.6 Objetivos

El presente trabajo se enmarca en el estudio de diversas técnicas de reconocimiento basado en dinámica de ratón. Así, sus objetivos son los siguientes:

- Implementación de un reconocedor de dinámica de ratón basado en la literatura existente. Se empleará la base de datos pública [5].
- Análisis y extracción de conocimiento de las técnicas expuestas en la literatura. Se estudiará el impacto de la selección de diferentes características y movimientos del ejercicio sobre los resultados. Además, se comprobará el efecto de diferentes propuestas de normalización y filtrado de datos.
- Estudio y desarrollo de una primera aproximación del modelado neuromotor basado en Sigma-Lognormal aplicado en dinámica de ratón. Para ello, se hará uso de la interfaz del modelo desarrollada por Plamondon y O'Reilly [17] y se desarrollarán las herramientas necesarias para la extracción de parámetros neuromotores de forma automática.
- Estudio de potenciales aplicaciones del modelado neuromotor de la dinámica de ratón orientadas al reconocimiento de personas.

1.7 Organización de la memoria

La memoria consta de los siguientes capítulos:

- **Capítulo 1. Introducción.** Se presenta una introducción al reconocimiento de patrones, al reconocimiento biométrico, al reconocimiento basado en dinámica de ratón y al modelo Sigma-Lognormal basado en la Teoría Cinemática. Además, se exponen los motivos que han impulsado el desarrollo de este trabajo y los objetivos planteados.
- **Capítulo 2. Metodología.** Se describe la base de datos empleada, así como su adaptación al modelo Sigma-Lognormal. A continuación, se exponen el resto de etapas de diseño. Esto es, se detallan las características extraídas y algoritmos utilizados.
- **Capítulo 3. Experimentación.** El marco experimental es presentado en este punto junto con los resultados de diversas pruebas realizadas.
- **Capítulo 4. Conclusiones y trabajo futuro.** Se resumen las conclusiones extraídas y se describen las posibles futuras líneas de trabajo planteadas.

2 Metodología

Este capítulo aborda la descripción de las diferentes etapas que conforman el diseño del sistema de reconocimiento. Se expone un análisis de la base de datos tomada y su preprocesado, la descripción de las características extraídas y el método de comparación.

2.1 Base de datos

En toda tarea de reconocimiento biométrico, la adquisición de datos de análisis es fundamental. Así, la disponibilidad de bases de datos abiertas al marco experimental resulta básica. La única base de datos de dinámica de ratón pública¹ es la desarrollada por Chao *et al.* [5], y será la empleada en este trabajo.

De acuerdo a [5], esta base de datos cuenta con las siguientes especificaciones iniciales:

- Está formada por **58 usuarios**, adquirida en un entorno controlado.
- La base de datos se presenta en formato texto, en dos niveles. El primero corresponde al nombre de usuario y el segundo a los archivos de las tareas realizadas. En cada uno de ellos se recogen cuatro parámetros: tipo de movimiento (clic/desplazamiento), posición en eje horizontal, posición en eje vertical y referencia temporal. Según la descripción, hay **300 archivos**, o repeticiones del ejercicio, por cada usuario.
- La referencia temporal tiene una precisión teórica de $\pm 15.625\text{ms}$.
- La realización de los ejercicios está supervisada, de forma que si el usuario comete un error (clics en posiciones erróneas o trayectoria desordenada), la tarea se reanuda.

	Dirección	Distancia (Píxeles)
1	↑	100
2	→	400
3	↙	700
4	↗	700
5	↓	400
6	↖	524
7	↘	100
8	←	100

Tabla 2.1. Listado de movimientos que componen el ejercicio. Datos obtenidos de [5].

¹ Enlace a la base de datos: <http://nskeylab.xjtu.edu.cn/people/cshen/data-sets/behavior-data-set/>

- Cada ejercicio está compuesto de **8 movimientos** separados por clics. La figura 2.1 muestra el ejercicio completo; los puntos azules son las muestras recogidas en la adquisición y dan una idea de la velocidad de trazado; los puntos rojos corresponden a clics. La tabla 2.1 enumera los movimientos contenidos en la tarea.




Figura 2.1. Ejercicio completo. Los círculos rojos representan los clics que dividen la tarea en los 8 movimientos (en trazo azul)

2.1.1 Preprocesado de la base de datos

En la primera fase de trabajo, se analizó el conjunto de datos y se extrajeron una serie de conclusiones, adicionales a la información anteriormente aportada. A partir de dichas resoluciones, a continuación enumeradas, se forzó un ajuste del conjunto de datos. Las especificaciones empíricas de la base de datos son las siguientes.

- **Cada usuario tiene un número diferente de archivos** o repeticiones, oscilando el total entre 40 y 400.
- Existen usuarios con carpetas vacías por lo que el **número real de usuarios válidos es de 42**.
- La referencia temporal no cumple la precisión mencionada, presentando intervalos alternos de 0ms o 15ms. Es decir, existen muestras con mismo tiempo de adquisición. Esto podría deberse a la falta de precisión del formato de número entero.
- **Cada archivo contiene** en realidad **dos repeticiones** de un mismo ejercicio, luego se dan un mínimo de 16 clics en total (mínimo porque se dan dobles clics y clics erróneos).
- Pese a ser un ejercicio controlado, no todas las repeticiones contienen el número de clics especificados.

Por ende, el número de usuarios de la base de datos es reducido forzosamente de 58 a 42, tras eliminar aquellos vacíos o con escasez de repeticiones. Del total de archivos de cada usuario, se han extraído y procesado por separado dos repeticiones. Aquellas tareas con menos clics de los especificados han sido eliminadas de las etapas de registro, entrenamiento

y test. Además, dado que existen más clics de los originalmente destinados a separar cada movimiento, se ha realizado un filtrado de los mismos. Se asume que, a fin de ignorar dobles clics, clics consecutivos deben tener un espaciado mínimo de 10 píxeles.

Por lo expuesto en el tercer punto, se asume que el proceso de muestreo se ha realizado a frecuencia constante, obviando la referencia temporal en el cálculo de algunos parámetros.

Una vez cerrado el conjunto de evaluación, se ha aplicado un filtrado paso bajo previo a la extracción de características a fin de mitigar la variabilidad interna de los datos. El filtrado consiste en un suavizado, promediando cada cinco muestras, y un diezmo de factor 3. La figura 2.2 muestra el efecto de este filtrado sobre diferentes tramos o movimientos del ejercicio.




Figura 2.2. Comparación de movimientos tras filtrado.

2.2 Extracción de características

Tras la adquisición de los datos y su preprocesado, se extraen las características que conformarán los modelos de comparación. En un sistema biométrico, la selección de un conjunto u otro de características tiene enorme relevancia en el rendimiento del clasificador.

La dinámica de ratón no dispone de una parametrización establecida. En un trazado se distinguen dos eventos: desplazamiento y clic. Muchos estudios se centran en la extracción de características a partir de la información de desplazamiento, ignorando los clics por ser aparentemente menos discriminantes. En la literatura [5], la dinámica de ratón es descrita generalmente en función a cuatro propiedades básicas: tiempo, distancia, velocidad y aceleración de cada movimiento.

En este trabajo, además de la extracción de dichas características, se extrae información basada en el modelo Sigma-Lognormal de la Teoría Cinemática. Dado que todo movimiento del ratón es gobernado por el sistema motor y cognitivo, la extracción de características neuromotoras cobra sentido.

2.2.1 Características de la literatura

Las características basadas en la literatura, propuestas por Chao *et al.* [5], se agrupan en dos clases: holísticas y dinámicas. Estas características se han extraído para cada movimiento que conforma el ejercicio. Como ya se ha mencionado, los movimientos están separados por clics. Así, cada par de clics determina el vector de datos sobre el que extraer los diferentes parámetros. Dado que existen 8 movimientos en un ejercicio y se extraen un total de 13 características (descritas a continuación), el vector de características tiene dimensión 104.

2.2.1.1 Características holísticas

Las características holísticas describen las propiedades generales del ejercicio. Las figuras 2.3, 2.4 y 2.5 muestran cada una de ellas, en forma de histograma, para tres movimientos representativos del conjunto: un tramo vertical corto, otro medio horizontal y uno largo diagonal (entre paréntesis se indican los píxeles). Sean \mathbf{t}^i , \mathbf{x}^i e \mathbf{y}^i los vectores de coordenadas cartesianas y sus marcas de tiempo asociadas del movimiento i -ésimo de una tarea (en la base de datos utilizada cada tarea consta de 8 movimientos divididos por clics), las características son las siguientes:

1. **Distancia de movimiento:** distancia recorrida entre dos clics consecutivos, es decir, desplazamiento en cada i -ésimo movimiento. Es calculada mediante:

$$D_i = \sum_{k=1}^N |x_k^i - x_{k-1}^i| + \sum_{k=1}^N |y_k^i - y_{k-1}^i|$$




Figura 2.3. Histogramas de la distancia de movimiento para tres tramos del ejercicio.

2. **Offset de movimiento:** distancia entre la trayectoria actual del ratón y la trayectoria recta. Basado en la propuesta de Aksari y Artuner [4], es calculada como la distancia ortogonal entre las muestras de movimiento y la línea que une dos clics consecutivos, según:

$$Offset_k^i = \left| \frac{(y_0 - y_1)x_k^i + (x_1 - x_0)y_k^i + (x_0y_1 - x_1y_0)}{(1 + D_i)} \right|$$

3. **Tiempo de movimiento:** diferencia de tiempo entre el primer y último punto de cada i -ésimo movimiento.

$$T_i = |t_1 - t_0|$$




Figura 2.4. Histogramas del offset de movimiento para tres tramos del ejercicio.




Figura 2.5. Histogramas del tiempo de movimiento para tres tramos del ejercicio.

2.2.1.2 Características dinámicas

Las características dinámicas son aquellas relativas al transcurso del movimiento, esto es:

4. **Velocidad en x:** velocidad en eje horizontal, calculada según:

$$v_{x_k}^i = |x_k^i - x_{k-1}^i|$$

5. **Velocidad en y:** velocidad en eje vertical, calculada según:

$$v_{y_k}^i = |y_k^i - y_{k-1}^i|$$

6. **Velocidad en x respecto a distancia:** velocidad en eje horizontal respecto a la distancia recorrida, calculada según:

$$vd_{x_k}^i = \frac{|x_k^i - x_{k-1}^i|}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

7. **Velocidad en y respecto a distancia:** velocidad en eje vertical respecto a la distancia recorrida, calculada según:

$$vd_{y_k}^i = \frac{|y_k^i - y_{k-1}^i|}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

8. **Velocidad media respecto a distancia:** velocidad media respecto a la distancia recorrida, calculada según:

$$v_{m_k}^i = \frac{\sqrt{(v_{x_k}^i)^2 + (v_{y_k}^i)^2}}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

9. **Aceleración en x:** aceleración en eje horizontal, calculada según:

$$a_{x_k}^i = |v_{x_k}^i - v_{x_{k-1}}^i|$$

10. **Aceleración en y:** aceleración en eje vertical, calculada según:

$$a_{y_k}^i = |v_{y_k}^i - v_{y_{k-1}}^i|$$

11. **Aceleración en x respecto a distancia:** aceleración en eje horizontal respecto a la distancia recorrida, calculada según:

$$ad_{x_k}^i = \frac{|v_{x_k}^i - v_{x_{k-1}}^i|}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

12. **Aceleración en y respecto a distancia:** aceleración en eje vertical respecto a la distancia recorrida, calculada según:

$$ad_{y_k}^i = \frac{|v_{y_k}^i - v_{y_{k-1}}^i|}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

13. **Aceleración media respecto a distancia:** aceleración media respecto a la distancia recorrida, calculada según:

$$a_{m_k}^i = \frac{|v_{m_k}^i - v_{m_{k-1}}^i|}{1 + \sqrt{(x_k^i - x_{k-1}^i)^2 + (y_k^i - y_{k-1}^i)^2}}$$

A fin de suavizar los resultados, el cálculo de cada una de estas características ha concluido con un **filtrado tipo promediado** con tamaño de ventana $N = 3$. La figura 2.7 sintetiza el resultado de las diferentes características calculadas, en forma de histograma, sobre el total de usuarios para tres movimientos del ejercicio.

En resumen, de cada ejercicio realizado por un usuario se procesan cada uno de los ocho movimientos por separado. Se extraen, por movimiento, las 13 características descritas. La figura 2.6 esquematiza el proceso seguido. El vector de parámetros de una tarea (o repetición) lo compondrán por tanto $8 \times 13 = 104$ **características**.




Figura 2.6. Etapas de extracción de características de la literatura.

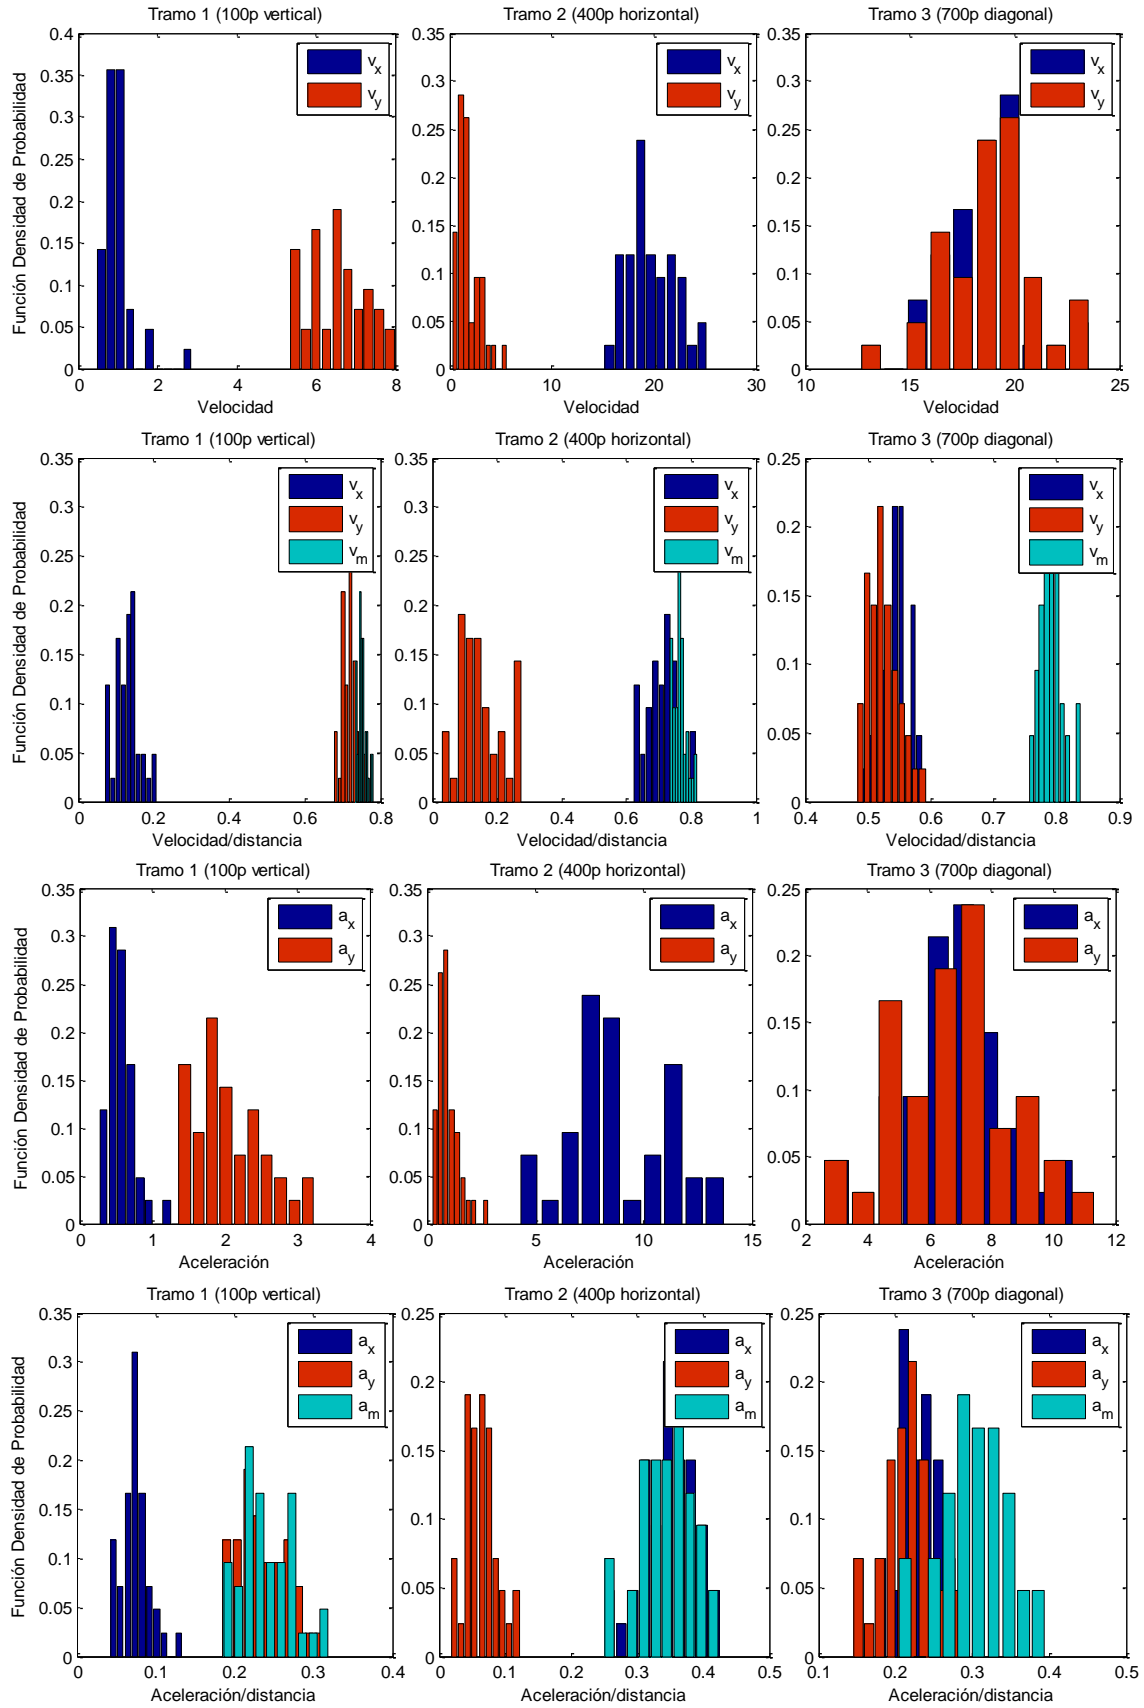


Figura 2.7. Histogramas de las características dinámicas para tres movimientos del ejercicio.

A la vista de los resultados reflejados en la figura 2.7, se observa alguna diferencia destacable. La principal reside en los tramos escogidos. Cada uno es fácilmente identificable dados los resultados (i.e., el tramo 1 presenta valores más altos en características relativas al eje vertical). Esta representación da una idea del carácter discriminante y variable que presentan algunos movimientos y la estabilidad de las características.

2.2.2 Características neuromotoras

De forma paralela a las anteriormente expuestas, se han calculado las características neuromotoras. Estas características parten de la parametrización del modelo Sigma-Lognormal.

2.2.2.1 Adaptación al modelo Sigma-Lognormal

El modelo Sigma-Lognormal se ha trabajado sobre el programa *ScriptStudio*, desarrollado por Plamondon y O'Reilly [17], véase la figura 2.8. A partir de los datos de entrada, la herramienta realiza un modelado neuromotor y ofrece como salida los parámetros que caracterizan dicho modelo para esos datos de entrada. En nuestro caso, la entrada serán los perfiles de velocidad de los movimientos del ratón. En este entorno, el conjunto de datos debe tener una estructura y formato muy concreto. Los datos, originalmente en formato texto, han sido convertidos a formato HWS siguiendo tres pasos:

1. Separación de las dos repeticiones del ejercicio contenidas en cada archivo de texto original.
2. Generación, para cada repetición, de una matriz con la información de tiempo normalizado, posición en x y posición en y .
3. Creación del archivo HWS insertando dicha matriz de acuerdo a una estructura establecida por el diseñador.

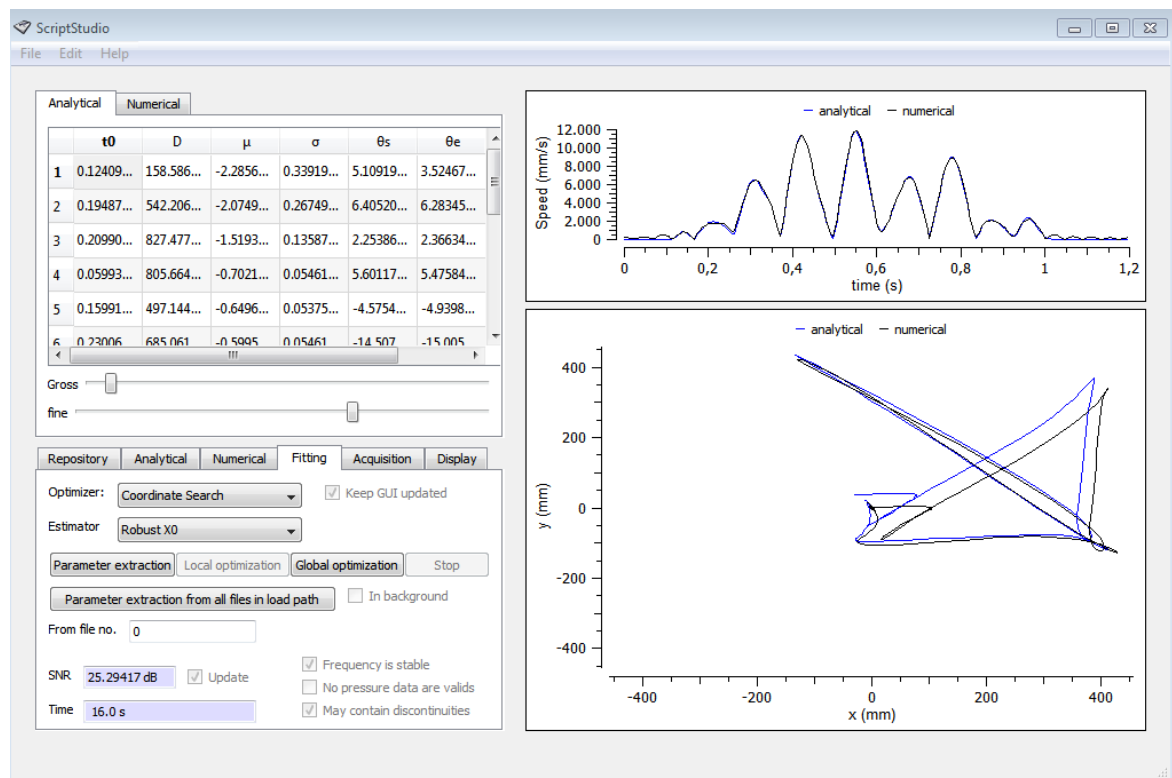


Figura 2.8. Interfaz de la aplicación de modelado neuromotor *ScriptStudio*.

En definitiva, del procesamiento de cada archivo de texto se han obtenido dos archivos HWS. Una vez convertido el conjunto total de datos, se han generado archivos *batch*, o de programación por lotes, por grupos de usuarios. Así, la extracción de parámetros neuromotores, mediante el ejecutable facilitado, resulta automática. La ejecución devuelve los parámetros analíticos del modelo, sobre los que se extraerán las características neuromotoras empleadas por el sistema. El proceso seguido se resume en la figura 2.9.




Figura 2.9. Esquema de adaptación de datos para extracción de características neuromotoras.

2.2.2.2 Extracción de características neuromotoras

El vector de características del modelo está formado por seis parámetros, resumidos en la tabla 2.2.

$$P_i = (t_{0i}, D_i, \theta_{d_i}, \theta_{f_i}, \mu_i, \sigma_i)$$

Estos parámetros son la salida del programa *ScriptStudio*, y se presentan como en el ejemplo de la figura 2.10. Cada columna corresponde a un parámetro y cada fila a una función lognormal que modela la señal de entrada.

1_2011726165839_logfile_task_2: Bloc de notas												
Archivo Edición Formato Ver Ayuda												
TypeFichier: ANA												
Version: 3												
NombreLognormales: 9												
-0.077008	154.375344	-1.195537	0.078160	4.545011	3.730441	0.000	0.000	1				
0.194842	474.230826	-2.265621	0.277017	12.518590	12.692083	0.000			0.000	1		
0.305522	143.276161	-2.796203	0.378104	4.859293	5.466817	0.000	0.000	1				
-0.100879	870.379916	-0.642699	0.051687	2.274161	2.435081	0.000	0.000	1				
0.125456	831.336914	-0.829225	0.055593	5.677353	5.256675	0.000	0.000	1				
-0.080536	555.360542	-0.310823	0.050000	-4.095050	-5.127007	0.000			0.000	1		
0.329036	609.302384	-0.811143	0.055593	-2.229120	-2.487193	0.000			0.000	1		
0.774221	194.310495	-2.489330	0.330323	6.781084	7.281135	0.000	0.000	1				
0.536636	128.596659	-0.872992	0.055593	3.439467	3.235602	0.000	0.000	1				

Figura 2.10. Ejemplo de parámetros de salida del modelo Sigma-Lognormal.

A partir de éstos, y en base a lo propuesto por Fischer y Plamondon [15], se han desarrollado los algoritmos para extraer **nueve características** (ver Tabla 2.2). Ha de tenerse en cuenta que la parametrización del modelo se ha realizado sobre el conjunto de movimientos que conforman un ejercicio. Luego se tienen nueve características por ejercicio, y no por movimiento. El motivo por el que se ha decidido procesar el ejercicio completo es el alto coste computacional y las propiedades de la parametrización del modelo. El modelo reduce la cantidad de datos a un conjunto de parámetros lognormal. Así, un ejercicio adquirido con unas 500 muestras se reduce a menos de 20 funciones lognormal,

como se observa en la figura 2.10. Si se realizase el procesado de cada movimiento por separado, apenas se tendrían una o dos funciones Sigma-Lognormal.

Las tres primeras características extraídas (D_i, μ_i, σ_i) coinciden con los parámetros del modelo. Las cuatro siguientes ($\sin \theta_{d_i}, \sin \theta_{f_i}, \cos \theta_{d_i}, \cos \theta_{f_i}$) son una transformación al eje cartesiano de los parámetros angulares. Se computa también la diferencia de tiempo de iniciación entre realizaciones (Δt_{0_i}) y el número de funciones lognormal N que modelan el ejercicio. La tabla 2.2 resume el conjunto de características extraídas.

Un ejercicio, en la parametrización descrita, viene representado por una matriz de tamaño $N \times 6$, donde N es el número de funciones lognormal que modelan cada trazo. Por tanto, vistas las características extraídas, el vector final tendrá dimensión $N \times 9$. El valor de N varía según usuario y repetición por lo que finalmente se calcula la media de cada parámetro entre las N lognormal disponibles. La figura 2.11 representa los histogramas de las diferentes características extraídas para el total de usuarios.

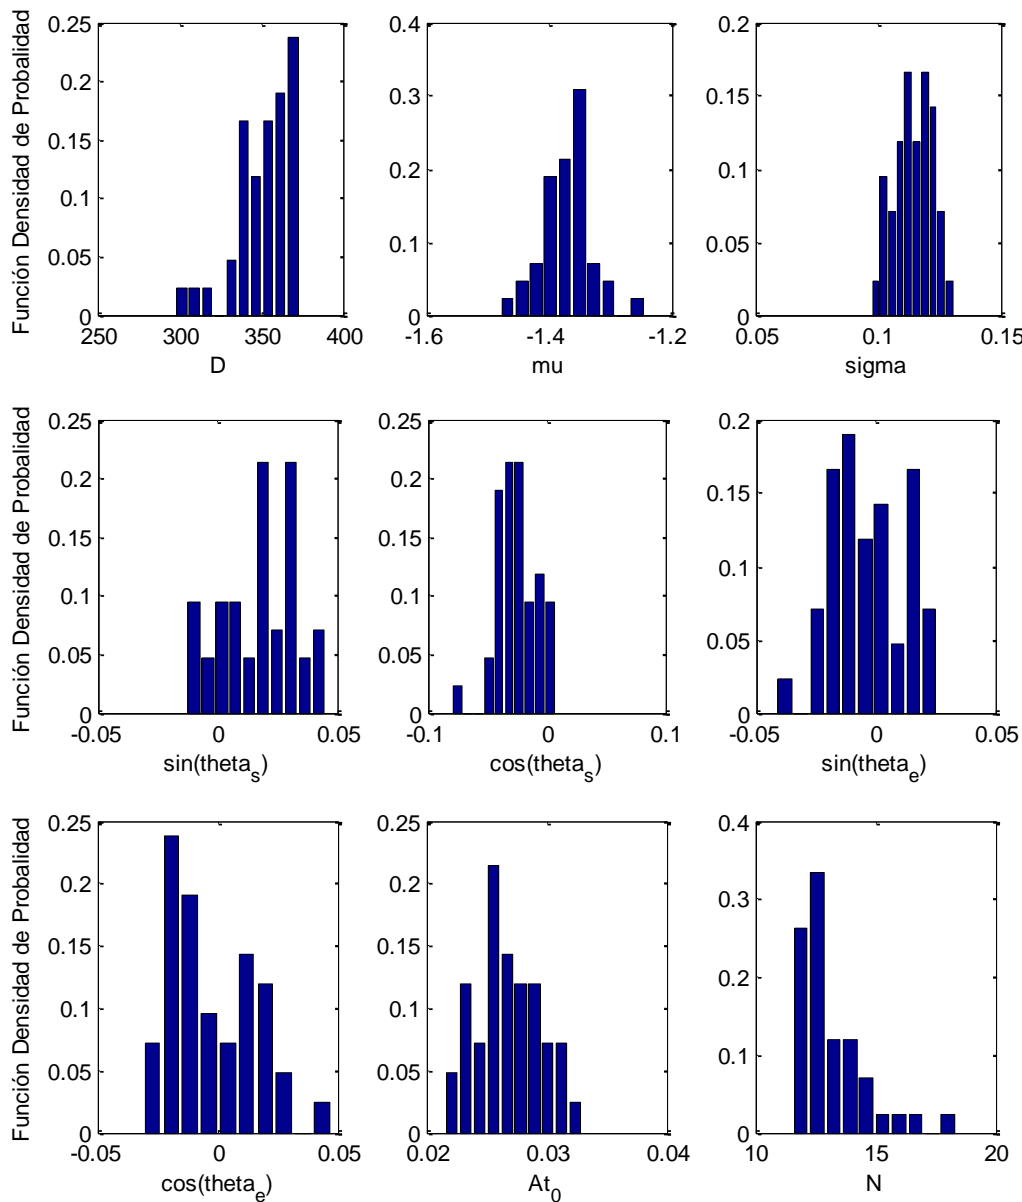


Figura 2.11. Histogramas de las características neuromotoras. Se representa el valor medio por usuario.

Parámetros del modelo Sigma-Lognormal		Características neuromotoras
1	t_0	Δt_0
2	D	D
3	μ	μ
4	σ	σ
5	θ_d	$\sin \theta_d$
6	θ_f	$\sin \theta_f$
7		$\cos \theta_d$
8		$\cos \theta_d$
9		N

Tabla 2.2. Parámetros del modelo Sigma-Lognormal y características neuromotoras.

2.3 Método de comparación

La etapa de comparación es la encargada de calcular una puntuación que evalúe cómo de similares son dos realizaciones del ejercicio. Esta puntuación, junto a un umbral, permitirá discriminar entre usuarios genuinos e impostores. Dados los resultados de la literatura [5], se ha decidido emplear la **distancia Manhattan**.

En nuestro sistema, el modelo de usuario se conforma a partir del valor medio de un conjunto realizaciones, representadas por un vector $\mathbf{g} = [g_1, g_2, \dots, g_N]$ de N características o vector de entrenamiento. Por otro lado, cada realización de test del ejercicio es caracterizada por un vector $\mathbf{f} = [f_1, f_2, \dots, f_N]$ de igual dimensión N . La distancia entre ambos vectores da lugar a la puntuación. La expresión de la distancia Manhattan normalizada que se aplica en esta etapa se expresa como sigue:

$$d = \sum_{k=0}^N \frac{|f_k - \bar{g}_k|}{\sigma_k}$$

donde \bar{g} y σ son, respectivamente, el valor medio y la desviación típica de las características del conjunto de entrenamiento.

En el caso concreto de las características de la literatura, se calcula un valor de distancia por cada i -ésimo movimiento o tramo caracterizado por su correspondiente vector de características (\mathbf{f}^i o \mathbf{g}^i), así:

$$d = \frac{1}{8 \times N} \sum_{i=1}^8 \sum_{k=0}^N \frac{|f_k^i - \bar{g}_k^i|}{\sigma_k^i}$$

La puntuación final del usuario será la media de las ocho distancias calculadas.

Por el contrario, las características neuromotoras parametrizan realizaciones completas del ejercicio. Así, su puntuación viene dada directamente por la distancia Manhattan entre vectores de entrenamiento y test.

De forma paralela, dada la variabilidad intrínseca en cualquier rasgo biométrico de comportamiento, se ha decidido emplear, a modo de prueba, la medida de distancia basada el **algoritmo DTW** (Dynamic Time Warping). La distancia DTW es calculada directamente sobre los datos en crudo de dos realizaciones. El principal motivo por el que se ha decidido emplear este algoritmo es que, generalmente, dos vectores de datos de comportamiento no constan exactamente de las mismas muestras. La puntuación extraída de este cálculo se ha combinado con la resultante de la distancia Manhattan sobre el conjunto de características.

2.4 Contribuciones del TFG

En lo que respecta a la extracción paramétrica de secuencias dinámicas de ratón, las contribuciones del presente TFG se resumen en:

- Implementación de algoritmos de extracción automática de características biométricas para secuencias dinámicas de ratón basadas en la literatura.
- Implementación de algoritmos de extracción automática de características biométricas basadas en parámetros neuromotores a partir de la herramienta *ScriptStudio*.
- Implementación de algoritmos de comparación de ambos tipos de características.

3 Experimentación

En este capítulo se expone el protocolo experimental que basa la realización de todas las pruebas. Los resultados de los experimentos de evaluación recogidos permiten extraer una serie de conclusiones sobre el rendimiento del sistema y las diversas aproximaciones en la tarea de reconocimiento de personas basado en dinámica de ratón. De forma general, los experimentos de los resultados se presentan en forma de curvas FAR, FRR y ROC.

Además, en este TFG se proponen y evalúan dos potenciales aplicaciones del modelado neuromotor de la dinámica de ratón: reconocimiento de usuario basado en características neuromotoras y detección de actividad humana a partir de modelado neuromotor.

3.1 Protocolo de experimentación

Se ha adaptado el protocolo experimental propuesto en [5] para así poder tener un rendimiento de referencia aproximado. Se consideran dos conjuntos de muestras por usuario, el conjunto de entrenamiento y el conjunto de test. El conjunto de entrenamiento, que constituye el modelo de usuario, está formado por sus primeras 150 repeticiones, de las cuales solo se utilizarán las 20 últimas realizaciones, por ser las de mayor estabilidad una vez el usuario ha interiorizado la tarea. El conjunto de test está formado por las muestras genuinas restantes y las cinco primeras realizaciones impostoras de cada uno de los otros usuarios. La tabla 3.1 resume el marco experimental.

Número de usuarios		42
Número de realizaciones por usuario		Mínimo 200
Conjunto de entrenamiento	Repeticiones 131 a 150 (se desechan las muestras de la 1 a la 130)	
Conjunto de test	Restantes a partir de la 150 si genuino 5 primeras si impostor	
Medida de distancia		Manhattan

Tabla 3.1. Tabla resumen del marco experimental.

Las realizaciones genuinas nos permiten calcular la tasa de falso rechazo, mientras que las impostoras nos permiten calcular la tasa de falsa aceptación, véase sección 1.2.2. Toda realización viene parametrizada por un vector de dimensión $13 \times 8 = 104$, en el caso de las características de la literatura, y 9 en el caso de las características neuromotoras. El modelo de usuario se forma a partir de la media de los vectores correspondientes a las realizaciones de entrenamiento. Para el cálculo de la distancia, se extrae el valor medio y la desviación típica del conjunto de entrenamiento y se compara con la realización de test parametrizada.

Así, el detector basado en características de la literatura extrae 8 valores de distancia por comparación. La puntuación se computa como el valor medio de los mismos. No obstante, el número de comparaciones genuinas vendrá determinado por el número de usuarios, 42; y

el conjunto de test, que varía para cada usuario dado que no todos tienen el mismo número de repeticiones. Se dispone en total de un mínimo de 42 (usuarios genuinos) \times 50 (muestras de test) = 2100 comparaciones genuinas. El número de comparaciones impostoras es 42 (usuarios genuinos) \times 41 (potenciales impostores) \times 5 (muestras de test) = 8610 resultados de comparaciones impostoras. El procedimiento se repite para la comparación de características neuromotoras.

3.1.1 Combinación de características

El detector basado en la combinación de ambos tipos de características se ha implementado de acuerdo a dos esquemas: combinación a nivel de característica y combinación a nivel de puntuación. En ambos, el conjunto de entrenamiento y test sigue las pautas reflejadas anteriormente.

La combinación a nivel de característica se lleva a cabo tras la etapa de extracción. El resultado de cada extractor son vectores de características de dimensión 104 y 9 , véase la sección 2.2. La entrada del nuevo clasificador es la concatenación de ambos vectores, véase la figura 3.1. Se ha de tener en cuenta que las características de la literatura se computan por movimiento o tramo del ejercicio, mientras que las características neuromotoras se calculan sobre el ejercicio completo. Así, la combinación de ambos vectores se ha realizado concatenando sus valores medios y desviación estándar, replicando el neuomotor en cada movimiento.

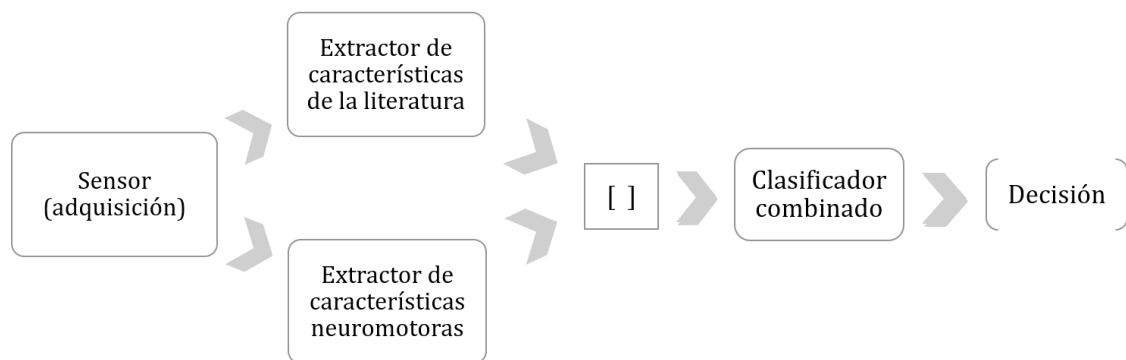


Figura 3.1. Esquema de detector con combinación a nivel de característica.

La combinación a nivel de puntuación se lleva a cabo en la etapa previa a la decisión. Los resultados de ambos clasificadores han sido combinados aritméticamente y normalizados con la tangente hiperbólica, formando la puntuación con la que tomar la decisión, véase la figura 3.2.

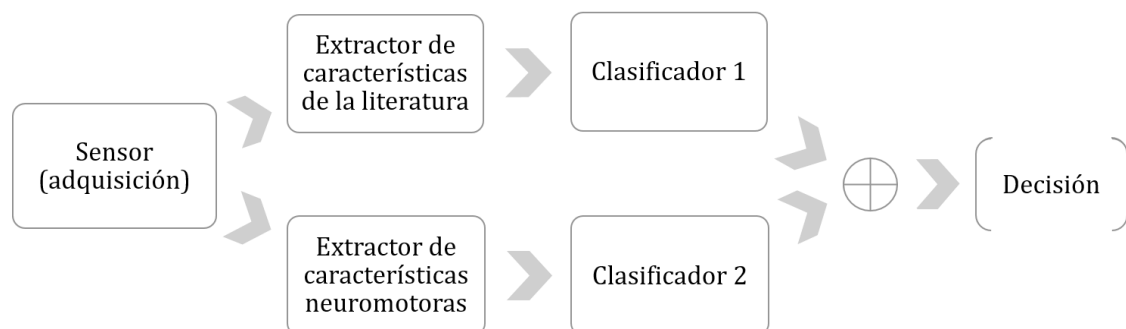


Figura 3.2. Esquema de detector con combinación a nivel de puntuación.

3.2 Pruebas y resultados

Mediante el protocolo expuesto en la sección anterior, se calculan las tasas de falsa aceptación y falso rechazo, FAR y FRR respectivamente, para cada usuario. De ello se extrae su EER. A fin de evaluar el rendimiento del sistema, las pruebas realizadas se presentan mediante el EER promedio y la desviación estándar de todos los usuarios.

3.2.1 Pruebas sobre el detector basado en características de la literatura

Se han realizado pruebas sobre el diseño implementado relativas a: los movimientos del ejercicio, las características extraídas y la medida de distancia. Todos los resultados obtenidos se ven afectados por la enorme variabilidad de los datos. Pese a tratar de solventarlo, este factor resulta significativo en todas las pruebas realizadas. Los valores de EER y desviación estándar del sistema inicial son, respectivamente, 24.15% y 9.83%. En base a ello, se van a realizar pruebas de cara a evaluar el impacto de los diferentes parámetros que lo definen y adquirir, así, conocimiento de la tarea.

Los resultados recogidos en la tabla 3.2 muestran los valores de EER y desviación estándar considerando únicamente un movimiento o tramo del ejercicio en la etapa de entrenamiento y test. De esta forma, se pretende evaluar qué tramos resultan más discriminantes para la tarea de autenticación. A la vista de los resultados, los movimientos más largos y que comprenden desplazamiento horizontal y vertical son más discriminantes. Además, el primer y último tramo, por ser también los más cortos, presentan menor tasa de desviación.

Movimiento incluido	EER (%)	Desviación estándar (%)
1 (↑ 100p)	36.90	5.75
2 (→ 400p)	36.69	8.68
3 (↙ 700p)	34.58	8.22
4 (↗ 700p)	33.43	10.56
5 (↓ 400p)	38.01	8.95
6 (↖ 524p)	34.82	9.35
7 (↘ 100p)	38.04	7.97
8 (← 100p)	36.78	5.21

Tabla 3.2. Resultados de EER y desviación estándar según movimiento incluido.

Del mismo modo, se evalúa el rendimiento de cada una de las características por separado, a fin de extraer conocimiento de las mismas. La tabla 3.3 muestra la tasa de error medio y desviación estándar incluyendo cada una de las características individualmente. A raíz de los resultados, las características que ofrecen peor tasa de error son el tiempo de movimiento y la velocidad en el eje horizontal respecto a la distancia. La información relativa al tiempo, como se explicó en la sección 2.1, carece de rigurosidad, lo que explica

el resultado. En cuanto a la velocidad en x , un posible planteamiento es asumir que los humanos somos más estables en movimientos horizontales que en verticales, más concretamente por la habitual posición del brazo sobre el soporte al desplazar el ratón. Por el contrario, las características relativas a la aceleración del movimiento son más discriminantes.

Característica incluida	EER (%)	Desviación estándar (%)
Distancia	35.24	9.21
Offset	37.63	6.33
Tiempo	40.57	8.26
Velocidad en x	34.97	9.31
Velocidad en y	32.97	9.31
Velocidad en x /distancia	38.02	8.18
Velocidad en y /distancia	37.78	8.87
Velocidad media	36.61	10.02
Aceleración en x	32.04	10.39
Aceleración en y	29.55	10.75
Aceleración en x /distancia	33.15	9.60
Aceleración en y /distancia	32.55	9.85
Aceleración media	32.23	10.76

Tabla 3.3. Resultados de EER promedio y desviación estándar según características incluidas en el detector.

De forma contraria al análisis de rendimiento en positivo anterior, se ha querido evaluar el rendimiento de diferentes conjuntos, de cara a encontrar el más óptimo. Para ello, se comprueban las tasas de error tras eliminar cada una de las características, véase la tabla 3.4. Resulta relevante cómo la falta de algunas características, a priori consideradas importantes, mejora los resultados. Un ejemplo de ello es la velocidad en el eje vertical respecto a la distancia. Es necesario tener en cuenta que se están tratando datos, muy variables, que responden a movimientos del sistema muscular. Aparentemente, en relación a la producción de movimientos por contracción muscular, movimientos realizados en dirección vertical son ligeramente más distintivos que movimientos en horizontal. Por otro lado, atendiendo a la desviación estándar, las características dinámicas (en fondo gris) parecen presentar menor estabilidad que las características holísticas. La falta de éstas últimas incrementa la variabilidad del conjunto ligeramente (i.e. eliminando la característica *distancia*, la desviación aumenta). Las características dinámicas, aunque filtradas, recogen más fielmente cada movimiento, lo que conlleva también la adquisición de parte del carácter variable intrínseco en la dinámica de ratón.

Característica eliminada	EER (%)	Desviación estándar (%)
ninguna	24.15	9.83
Distancia	24.79	10.36
Offset	24.31	9.88
Tiempo	25.23	9.89
Velocidad en x	23.72	9.68
Velocidad en y	24.24	9.91
Velocidad en x/distancia	24.04	9.80
Velocidad en y/distancia	23.89	9.86
Velocidad media	24.47	9.74
Aceleración en x	23.86	9.54
Aceleración en y	24.33	9.65
Aceleración en x/distancia	24.08	9.53
Aceleración en y/distancia	24.05	9.71
Aceleración media	24.30	9.63

Tabla 3.4. Resultados de EER promedio y desviación estándar según características eliminadas del detector.

Vistos los resultados de las tablas 3.3 y 3.4, se comprueba la efectividad de ponderar con pesos cada característica, acorde a su rendimiento. Al no presentar mejora, se decide eliminar las características de peor rendimiento (i.e., en las tablas, aquellas que tras eliminarse dan lugar a un menor EER). Así, las siguientes pruebas evalúan el conjunto sin considerar la velocidad en x , la velocidad en y respecto a la distancia y la aceleración en x . En este nuevo entorno, figura 3.3, se obtiene un EER promedio de 23.31% y una desviación estándar de 9.59%.




Figura 3.3. Resultados de EER por usuario del clasificador basado en distancia Manhattan.

Otra prueba realizada ha sido el impacto del uso del algoritmo DTW en la etapa de clasificación. Los resultados de EER promedio ascienden a 41.76%. En contra de lo inicialmente pensado, este algoritmo no mejora los resultados. El alineamiento entre señales de este tipo parece eliminar información relevante para el sistema. Esto es porque el desarrollo del ejercicio propuesto está controlado, de forma que todos los usuarios deben empezar y acabar en el mismo punto. Las diferencias surgidas en el camino componen la información de inter-variabilidad. Aun así, no se descarta que mejoras y adaptaciones del algoritmo a la problemática asociada al reconocimiento basado en dinámica de ratón, puedan hacer que el algoritmo DTW alcance mejores resultados.

Para concluir este apartado, resulta interesante analizar los resultados de aquellos usuarios con mejor y peor rendimiento. La diferencia observada entre uno y otro supera el 40%, véase la figura 3.4. Esta enorme divergencia es llamativa, ya que ambos usuarios realizan el mismo ejercicio, bajo las mismas condiciones y el número de ficheros que componen el conjunto de entrenamiento y test es igual. Ante esta enorme variabilidad, establecer unas condiciones de diseño óptimas es una tarea compleja.




Figura 3.4. Comparativa de curvas ROC del usuario con mejor y peor rendimiento.

Las figuras 3.5 y 3.6 recogen tres realizaciones aleatorias correspondientes a cada uno de los usuarios analizados. A simple vista, se observa una estabilidad de mayor valor en el usuario de mejor rendimiento. Por el contrario, la alta inestabilidad de los datos del usuario contrario explica los resultados de EER obtenidos.




Figura 3.5. Ejemplo de tres realizaciones de un usuario que presenta baja tasa de error.




Figura 3.6. Ejemplo de tres realizaciones de un usuario que presenta alta tasa de error.

3.2.2 Pruebas sobre el detector basado en características neuromotoras

En la aplicación del modelo Sigma-Lognormal se extraen una serie de características propuestas en [15]. El rendimiento del conjunto inicial tiene una tasa de error medio de 44.99%. Pese a lo inicialmente esperado, este valor desvela la ineficiencia de esta técnica en la tarea de autenticación. Sin embargo, se consigue una reducción de la variabilidad del conjunto, expresada en valores más bajos de desviación estándar (se consigue un 2.89%).

Descartada su aplicación en autenticación, se realizan pruebas destinadas a extraer conocimiento de los parámetros propuestos. Con este fin, y no tratando de mejorar el rendimiento, se ha realizado una prueba similar a la reflejada en la tabla 3.3. Así, la tabla 3.5 refleja el impacto de cada parámetro observando los resultados derivados de su rendimiento por separado. Si bien la mayoría de los parámetros otorgan valores cuasi-aleatorios, cabe destacar el resultado de la desviación estándar. Como se explicó en la sección 2.2.2.2, el modelado Sigma-Lognormal reduce la dimensionalidad de los datos de cientos de muestras a decenas de funciones lognormal. Esto trae consigo una disminución de la desviación pero también, irremediablemente, una pérdida de capacidad de discriminación.

Característica incluida	EER (%)	Desviación estándar (%)
D	48.84	2.50
μ	50.32	2.59
σ	50.06	2.36
$\sin \theta_d$	46.95	1.75
$\cos \theta_d$	51.06	2.57
$\sin \theta_f$	50.37	1.74
$\cos \theta_f$	48.33	2.99
Δt_0	50.26	2.16
N	45.43	3.60

Tabla 3.5. Resultados de EER promedio y desviación estándar según características neuromotoras incluidas.

A fin de comprobar si existen diferencias significativas entre usuarios, se ha realizado una prueba con un grupo controlado. En base a los resultados plasmados en la figura 3.3, se han escogido los tres usuarios de mejor y peor rendimiento. De cada conjunto, se han extraído y promediado las características neuromotoras, véase la tabla 3.6. Si bien algunas presentan mayor diferencia, ni las características referidas al ángulo direccional inicial y final (θ_d, θ_f) ni las características que parametrizan la respuesta del impulso lognormal del sistema neuromuscular (μ, σ) presentan variación notable alguna, véase la figura 3.7. Sin embargo, el número de funciones lognormal N se incrementa en usuarios de peor rendimiento. Este factor se explica por la elevada variabilidad intrínseca en este tipo de usuarios, que requerirá mayor número de funciones para modelar un mismo ejercicio. Por otro lado, como cabía esperar, la longitud media del ejercicio (D) es mayor en los usuarios de peor rendimiento; los usuarios más estables realizan el trazado más fielmente. La predicción del rendimiento de un usuario a partir de un análisis neuromotor de sus tareas sería un hito importante que permitiría adaptar los modelos y esquemas de reconocimiento según el usuario [24].

	D	μ	σ	$\sin \theta_d$	$\cos \theta_d$	$\sin \theta_f$	$\cos \theta_f$	Δt_0	N
Usuarios de alto rendimiento	337,95	-1,32	0,116	0,0123	-0,0337	-0,001	0,0075	0,0258	12,38
Usuarios de bajo rendimiento	351,55	-1,35	0,113	0,0185	-0,0293	-0,005	-0,009	0,0264	14,27

Tabla 3.6. Características neuromotoras promediadas de los usuarios con peor y mejor rendimiento.

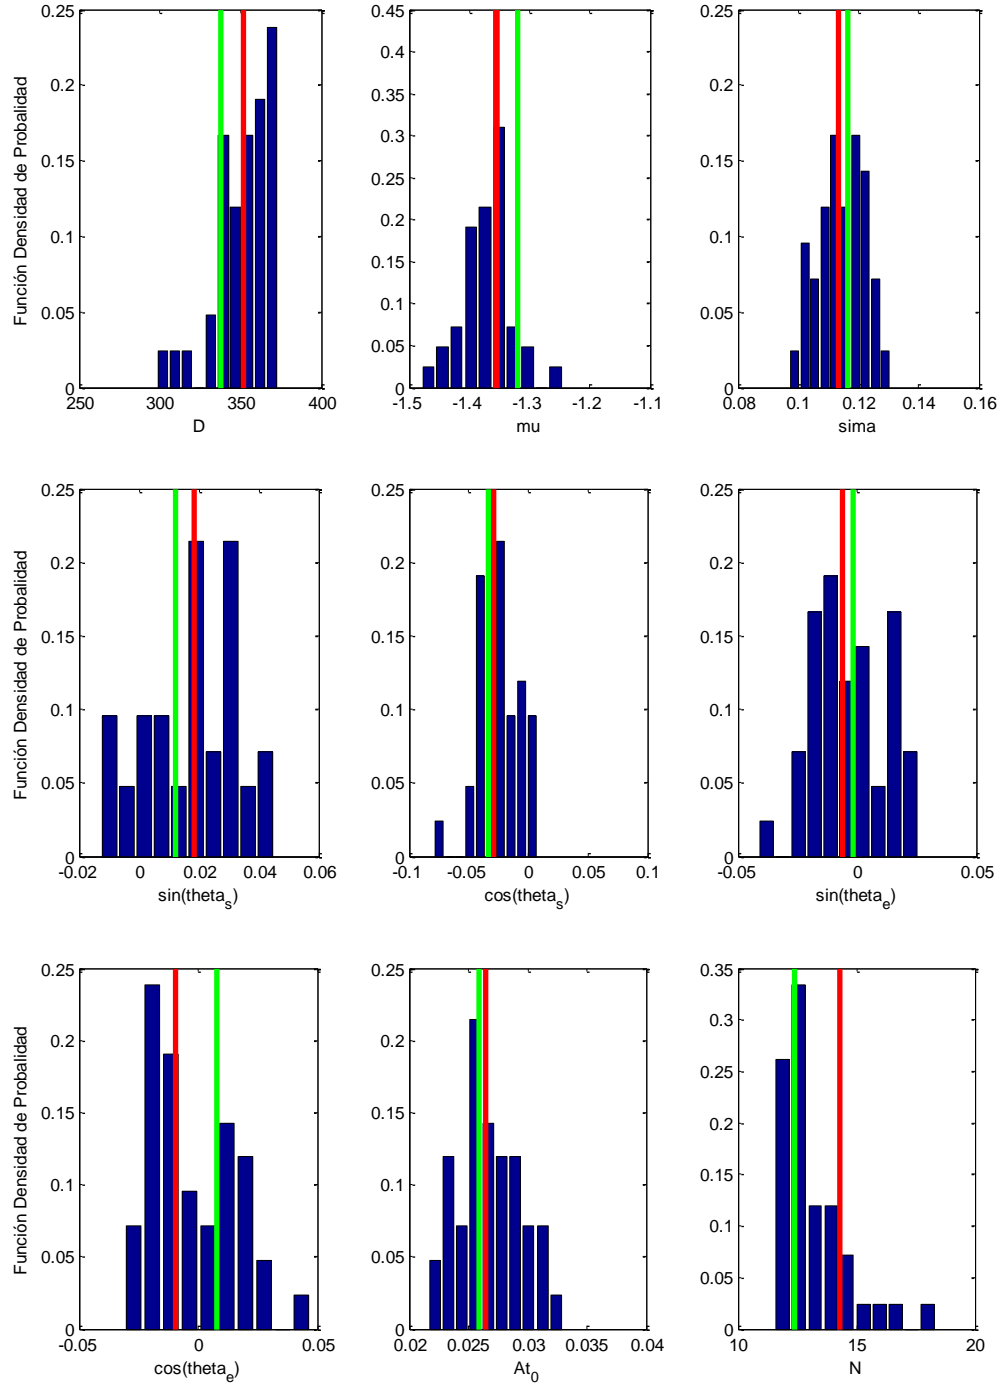


Figura 3.7. Comparación de características neuromotoras promediadas de los usuarios con peor (en rojo) y mejor rendimiento (en verde) sobre los histogramas del conjunto completo de usuarios.

3.2.3 Pruebas sobre el detector combinado

Dado el rendimiento del clasificador basado en las características neuromotoras, los resultados del detector combinado empeorarán respecto al primer esquema expuesto, sección 3.2.1. La tabla 3.7 refleja los resultados de EER promedio y desviación estándar de las dos implementaciones desarrolladas.

	EER (%)	Desviación estándar (%)
Combinación a nivel de característica	36.10	5.73
Combinación a nivel de score	36.52	5.23

Tabla 3.7. Resultados de EER promedio y desviación estándar del detector combinado.

De nuevo, los resultados reflejan el impacto del modelo neuromotor sobre la variabilidad del conjunto, en parte por la elevada reducción de la dimensionalidad de los datos que acarrea. Frente a la prueba anterior, la tasa de error baja por el efecto de las características de la literatura. La combinación a nivel de puntuación permite ponderar los pesos de cada una de las puntuaciones previas extraídas pero aun así, los resultados distan de los obtenidos por el sistema de mejor rendimiento (alrededor del 23%). A día de hoy, no está claro cómo utilizar la caracterización neuromotora para mejorar el rendimiento del sistema en términos de tasas de error.

3.2.4 Pruebas sobre el modelado Sigma-Lognormal para detección de actividad humana

Visto que el modelo Sigma-Lognormal no presenta buen rendimiento en la tarea de autenticación de personas, se ha realizado una prueba adicional que muestra nuevas posibles líneas de trabajo.

El modelo Sigma-Lognormal realiza un procesamiento del conjunto de datos de entrada a fin de ser correctamente descritos. Este procesamiento está dirigido a un tipo de datos concreto: aquellos que recogen movimientos gobernados por el sistema motor y cognitivo, es decir, trazados realizados por un ser humano. En este punto, se plantea evaluar cuál sería el resultado ante un trazado simulado artificialmente. Basado en el ejercicio adquirido en la base de datos, se ha computado una realización completamente rectilínea, véase la figura 3.8.




Figura 3.8. Realización simulada.

El procesamiento y parametrización de esa realización por el modelo Sigma-Lognormal se recoge en la figura 3.9. Se puede observar cómo el trazado es filtrado, presentando una forma suavizada. Sin embargo, el perfil de velocidad presenta gran diferencia respecto al de un trazado humano. Esta propiedad permite contemplar el modelo Sigma-Lognormal como una

herramienta válida para la detección de actividad humana (i.e. determinar cuándo el usuario es o no humano), por ejemplo, en pruebas tipo *CAPTCHA* basados en dinámica de ratón. Los parámetros extraídos por el modelo tras recibir como entrada la simulación propuesta se recogen en la tabla 3.8, junto al promedio que resulta del total de los usuarios. Esto establece una comparación entre los parámetros representativos de un humano y de la máquina. Se observan claras diferencias, tanto en distancia como en parámetros angulares. Además, el número de funciones lognormal que modela la simulación supera notablemente la media habitual de un humano.




Figura 3.9. Parametrización del modelo Sigma-Lognormal de la realización de la figura 3.8.

	t_0	D	μ	σ	θ_d	θ_f
Usuarios reales	0,1831	351,375	-1,370	0,1145	-3,492	-3,8144
Máquina	0,5759	211,123	-1,628	0,2120	18,7822	18,9121

Tabla 3.8. Comparación de parámetros lognormal entre usuarios reales y una realización simulada por la máquina.

Esta prueba es una ligera aproximación al problema planteado, si bien simulaciones más complejas, no rectilíneas, obtendrían diferentes resultados. Factor que, en caso de conocerlo, podría ser aprovechado igualmente por posibles falsificadores o hackers. No obstante, la figura 3.10 permite comparar el perfil de velocidad de un usuario frente al de una realización simulada por la máquina. A simple vista, se aprecia clara diferencia entre ambos.




Figura 3.10. Comparación de un perfil de velocidad de un usuario (arriba) y de una máquina (abajo).

3.3 Contribuciones del TFG

En relación al ámbito experimental, las contribuciones del presente TFG se resumen en los siguientes puntos:

- Evaluación del rendimiento de características biométricas extraídas de la dinámica de ratón a partir de medidas propuestas en la literatura y nuevas características neuromotoras.
- Extracción de conocimiento de la dinámica de ratón en base a las características de la literatura y neuromotoras.
- Uso del modelado neuromotor para detectar actividad humana a partir de la dinámica de ratón.

4 Conclusiones y trabajo futuro

4.1 Conclusiones

La fiabilidad demandada en los sistemas de autenticación de personas a partir de rasgos biométricos de comportamiento es cada vez mayor. Estos sistemas se han convertido en una necesidad clave en la sociedad actual por su conveniencia en entornos digitales. Pese a ser una biometría relativamente nueva, las amplias posibilidades del reconocimiento biométrico basado en dinámica de ratón han impulsado su investigación para su futura implantación en estos sistemas. Esta tecnología, caracterizada por su fácil adquisición e implantación y su bajo coste, supone una alternativa a complejos sistemas de monitorización y autenticación previos. En este trabajo se ha realizado el diseño y evaluación de un sistema de autenticación de personas basado en dinámica de ratón, propuesto en [5], empleando diversos algoritmos.

Sobre la base de datos prestada, se han realizado experimentos de acuerdo a dos conjuntos de características: las características propuestas en la literatura y las características neuromotoras basadas en el modelo Sigma-Lognormal. En el análisis de los resultados ha de tenerse en cuenta uno de los problemas fundamentales del conjunto de datos: la variabilidad intra-usuario (i.e., la variabilidad entre las muestras de un mismo usuario). Las realizaciones del ejercicio de un usuario difieren considerablemente unas de otras. Como consecuencia, las puntuaciones de similitud son más bajas y se incrementa la tasa de error del sistema. Para afrontar este problema se han estudiado diversos mecanismos basados en filtrados y normalización. Sin embargo, dados los resultados obtenidos, un factor principal que deberá tenerse en cuenta en futuros trabajos ha de ser el diseño del ejercicio planteado a los usuarios. En nuestro caso, la base de datos ha sido tomada con un ejercicio ya propuesto. Las especificaciones de la base de datos en [5] distan de las encontradas realmente, véase sección 2.1. Este factor, unido a la falta de información específica sobre el diseño del sistema, ha dificultado conseguir los objetivos inicialmente planteados. Así, se ha apostado por extraer conocimiento concreto de la tarea, expresado en una serie de conclusiones.

En el análisis de los movimientos que componen el ejercicio, se ha tratado de evaluar qué tramos resultan más discriminantes para la tarea de autenticación y se ha concluido que los movimientos más largos y que comprenden desplazamiento en ambas direcciones, horizontal y vertical, son más discriminantes. Además, destaca que el primer y último tramo sean los más estables, es decir, presenten menor tasa de desviación.

Atendiendo a las características de la literatura, se ha evaluado su rendimiento por separado a fin de extraer una serie de conclusiones. En primer lugar, las características relativas a la aceleración son las más discriminantes. Por otro lado, la información sobre movimiento en el eje horizontal da lugar a peores resultados. En este caso, se asume que los humanos somos más estables en movimientos horizontales que en verticales, posiblemente por la habitual posición del brazo sobre el soporte al desplazar el ratón. Esto podría explicar por qué movimientos realizados en dirección vertical resultan ser más distintivos que movimientos en horizontal. Por otro lado, atendiendo a la desviación estándar, las características dinámicas parecen presentar menor estabilidad que las características holísticas. Las características dinámicas, aunque filtradas, recogen más fielmente cada movimiento, lo que conlleva también la adquisición de parte del carácter variable intrínseco en la dinámica de ratón.

Del mismo modo, las pruebas realizadas con DTW no mejoran el rendimiento. Aparentemente, el alineamiento temporal no es factor necesario por desarrollarse el ejercicio en un entorno controlado, si bien posibles mejoras y adaptaciones del algoritmo al problema específico de la dinámica de ratón podrían mejorar sus resultados.

Las características de la literatura obtienen mejor resultado que las características neuromotoras. Éstas últimas resultan poco discriminantes para la tarea de autenticación de personas. Sin embargo, el interés por el modelado Sigma-Lognormal sigue vigente para otro tipo de aplicaciones. Este modelo tiene en cuenta los efectos relacionados con los tiempos de respuesta neuromusculares, con lo que se espera hallar su aplicación en la dinámica de ratón. Como se ha mostrado en las secciones 3.2.3 y 3.2.4, este tipo de parametrización puede encontrar utilidad en la detección de actividad humana así como en la clasificación de tipos de usuarios. Esto halla su interés en, por ejemplo, pruebas tipo *CAPTCHA* que empleen la dinámica de ratón como elemento de análisis. Según se ha probado, la respuesta ante una parametrización basada en el sistema cognitivo humano permite distinguir entre usuarios reales y la máquina. En relación a la clasificación de tipos de usuarios, las pruebas detalladas han mostrado cómo usuarios de peor rendimiento, caracterizados por una elevada variabilidad, presentan resultados de parametrización diferentes frente a usuarios estables. En términos de funciones lognormal, distancias recorridas y demás parámetros, estos usuarios son distinguibles entre sí, permitiendo establecer grupos en base a una predicción de su rendimiento. La importancia de esta clasificación reside en la posibilidad de adaptar modelos de reconocimiento según el usuario.

4.2 Trabajo futuro

Como trabajo futuro se plantean los siguientes objetivos:

- Generación de una base de datos rigurosa. Se propone crear una base de datos pública y correctamente especificada de acuerdo a un diseño óptimo de ejercicios, sesiones y número de usuarios.
- Estudio del impacto del diseño del ejercicio planteado a los usuarios.
- Estudio de técnicas complejas de reducción de variabilidad. Visto que la variabilidad es el mayor problema al que se enfrenta la dinámica de ratón, se propone dirigir un trabajo específico a la búsqueda de técnicas robustas de reducción de variabilidad.
- Generación de un sistema de autenticación continua. En relación al impacto del diseño del ejercicio, se plantea desarrollar un sistema de autenticación continua, es decir, basado en una dinámica libre.
- Lanzamiento de una competición pública a fin de reimpulsar y clarificar el estado de arte. Se persigue poner en común los avances existentes hasta la fecha.
- Profundización en la tarea de detección de actividad humana basado en el modelado Sigma-Lognormal.

Referencias

- [1]. M. Tapiador-Mateos (coord.) and J. A. Sigüenza-Pizarro (coord.), *Tecnologías biométricas aplicadas a la seguridad*. RA-MA Editorial, 2005.
- [2]. A. K. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 4–20, 2004.
- [3]. A. K. Jain, P. Flynn, and A. A. Ross, *Handbook of biometrics*. Springer Science & Business Media, 2007.
- [4]. Y. Aksari and H. Artuner, "Active authentication by mouse movements," in *Proceedings of the 24th International Symposium on Computer and Information Sciences*, pp. 571–574, 2009.
- [5]. S. Chao, C. Zhongmin, G. Xiaohong and R. Maxion, "Performance evaluation of anomaly-detection algorithms for mouse dynamics," *Computers and Security*, vol. 45, pp. 156–171, 2014.
- [6]. A. A. E. Ahmed and I. Traore, "A new biometric technology based on mouse dynamics," *IEEE Transactions on Dependable and Secure Computing*, vol. 4, no. 3, pp. 165–179, 2007.
- [7]. A. Syukri, E. Okamoto and M. Mambo, "A user identification system using signature written with mouse," C. Boyd, E. Dawson (Eds.), *Proceeding of the 3rd Australasian Conference on Information Security and Privacy*, Springer Berlin/Heidelberg, Queensland, Australia, pp. 403–414, 1998.
- [8]. R. A. J. Everitt and P. W. McOwan, "Java-based internet biometric authentication system," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 25, no. 9, pp. 1166–1172, 2003.
- [9]. S. Hocquet, J. Ramel, H. Cardot, "Users authentication by a study of human computer interactions," in *Proceedings of the 8th Annual (Doctoral) Meeting on Health, Science and Technology*, 2004.
- [10]. S. Hashia, C. Pollett, M. Stamp, "On using mouse movements as a biometric," in *Proceedings of the International Conference on Computer Science and its applications*, 2005.
- [11]. H. Gamboa, A. L. N. Fred and A. K. Jain, "Webbiometrics: user verification via web interaction," in *Biometrics Symposium*, pp. 1–6, 2007.
- [12]. P. Bours and C. J. Fullu, "A login system using mouse dynamics," in *Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, pp. 1072–1077, 2009.
- [13]. S. Chao, C. Zhongmin, G. Xiaohong, W. Jialin, "On the effectiveness and applicability of mouse dynamics biometric for static authentication: a benchmark study," *Biometrics (ICB)*, 5th IAPR International Conference on, pp. 378–38, 2012.
- [14]. B. Sayed, I. Traore, I. Woungang, M.S. Obaidat, "Biometric authentication using mouse gesture dynamics," *IEEE Systems Journal*, vol. 7, pp. 262–274, 2013.

- [15]. A. Fischer and R. Plamondon, "A Dissimilarity Measure for On-Line Signature Verification Based on the Sigma-Lognormal Model," Céline Rémi; Lionel Prévost; Eric Anquetil. 17th Biennial Conference of the International Graphonomics Society, Jun 2015, Pointe-à-Pitre, Guadeloupe. 2015, Drawing, Handwriting Processing Analysis: New Advances and Challenges.
- [16]. M. Gomez-Barrero, J. Galbally, J. Fierrez, J. Ortega-García, "Sobre cómo varían las firmas manuscritas con el tiempo: una modelización Sigma Lognormal," Biometric Recognition Group – ATVS, EPS, Universidad Autónoma de Madrid, 2013, in http://atvs.ii.uam.es/files/2013_JRBP_FirmaTiempo.pdf
- [17]. R. Plamondon and C. O'Reilly, "Development of a Sigma-Lognormal representation for on-line signatures," Pattern Recognition, vol. 42, issue 12, pp. 3324–3337, 2009.
- [18]. A. K. Jain, A. Ross and S. Pankanti, "Biometrics: A Tool for Information Security," in IEEE Transactions on Information Forensics and Security, vol. 1, no. 2, 2006.
- [19]. H. Gamboa and A. Fred, "A Behavioural Biometric System Based on Human Computer Interaction," Biometric Technol Hum Identif, pp. 381–392, 2004.
- [20]. D.A. Schulz, "Mouse curve biometrics," Biometric Consortium Conference, Biometrics Symposium: Special Session on Research at the, pp. 1–6, 2006.
- [21]. S. Chao, C. Zhongmin, G. Xiaohong, S. Huilan and D. Jingzi, "Feature analysis of mouse dynamics in identity authentication and monitoring," Communications, ICC '09 IEEE International Conference on pp. 1–5, 2009.
- [22]. A. A. E. Ahmed and I. Traore, "Anomaly intrusion detection based on biometrics," in Proceedings from the Sixth Annual IEEE SMC Information Assurance Workshop, pp. 452–453, 2005.
- [23]. S. Chao, C. Zhongmin, G. Xiaohong, D. Youtian and R. A. Maxion, "User Authentication Through Mouse Dynamics," in IEEE Transactions on Information Forensics and Security, vol.8, no.1, 2013.
- [24]. A. Morales, J. Fierrez and J. Ortega-Garcia, "Towards predicting good users for biometric recognition based on keystroke dynamics", in Proc. of European Conference on Computer Vision Workshops, Springer LNCS-8926, pp. 711-724, Zurich, Switzerland, 2014.

